

مقدمة في الاقتصاد القياسي

تأليف الأستاذ الدكتور
محمد صالح تركي القرشي

الطبعة الأولى
2004



الإهداء

* الى أساتذة تعلمت منهم

* الى طلابي

* الى اسرتي زوجتي وبناتي

وابني علاء

المحتويات

الصفحة	الموضوع
9	المقدمة
13	الفصل الأول / تعريف علم الإقتصاد القياسي
14	الإقتصاد القياسي بوصفه موضوعاً مستقلاً
16	طبيعة علم الإقتصاد القياسي
17	أغراض الإقتصاد القياسي
23	ما هو النموذج ؟
26	أنواع النماذج
31	أنواع العلاقات الإقتصادية
32	منهجية البحث العلمي في الإقتصاد القياسي
37	أنواع الإقتصاد القياسي
39	الفصل الثاني / نظرية الارتباط
41	مقدمة
44	قياس الارتباط الخطي
54	معامل ارتباط الرتب
56	معاملات الارتباط الجزئي
58	حدود نظرية الارتباط الخطي
63	الفصل الثالث / طبيعة تحليل الإنحدار
65	الأصل التاريخي لمصطلح الإنحدار
65	التفسير الحديث للإنحدار
69	الإعتماد الإحصائي مقابل الإعتماد الدالي
71	الفصل الرابع / تحليل الإنحدار البسيط
73	مقدمة
79	مفهوم دالة إنحدار المجتمع الإحصائي
81	التحديد الإحتمالي لدالة إنحدار المجتمع الإحصائي
83	دالة إنحدار العينة
91	الفصل الخامس / نموذج الإنحدار الخطي البسيط وطريقة المربعات الصغرى الإعتيادية

المحتويات

93	مقدمة
الصفحة	الموضوع
94	نموذج الانحدار الخطي البسيط
104	إفتراضات نموذج الانحدار الخطي الإحتمالي
112	معيان المربعات الصغرى والمعادلات الإعتيادية للمربعات الصغرى الإعتيادية
120	إشتقاق المعادلات الطبيعية أو الإعتيادية
127	تقدير الدالة التي يكون تقاطعها مع المحور العمودي صفراً
128	تقدير المرونات من خط الانحدار المقدر
131	الفصل السادس / الانحدار المتعدد
133	نموذج ذو متغيرين توضيحيين
143	نموذج العلاقات غير الخطية في الانحدار
145	تحويل الدوال غير الخطية التي تحتوي مرونات ثابتة الى دوال خطية
147	الفصل السابع / الإختبارات الإحصائية لمعنوية المعلمات المقدرية بطريقة المربعات الصغرى الإعتيادية
149	مقدمة
150	إختبار جودة توفيق خط الانحدار بإستخدام مربع معامل الإرتباط (r^2)
154	إختبار الخطأ المعياري للمعلمات المقدرية ($\hat{b}_1 \hat{b}_0$) بطريقة المربعات الصغرى الإعتيادية
157	إختبار (Z) للمعلمات المقدرية بطريقة المربعات الصغرى
163	إختبار (t) للمعلمات المقدرية بطريقة المربعات الصغرى
168	حدود الثقة للمعلمات ($\hat{b}_1 \hat{b}_0$)
172	الفصل الثامن / تحليل التباين
175	مقدمة
177	طريقة تحليل التباين بوصفها طريقة إحصائية
179	إختبار الفرق بين المتوسطات الحسابية
193	إختبار (F) لمعنوية خط الانحدار
197	الفصل التاسع مشكلات الانحدار / مشكلة الإرتباط الخطي المتعدد

المحتويات

199	مقدمة
200	أسباب ظهور أو وجود مشكلة الارتباط الخطي المتعدد
الصفحة	الموضوع
202	ما يترتب على وجود الارتباط الخطي المتعدد
208	إختبارات للكشف عن وجود الارتباط الخطي المتعدد
224	بعض الحلول لمشكلة الارتباط الخطي المتعدد
229	الفصل العاشر / مشكلات الإنحدار / مشكلة الارتباط الذاتي
231	مقدمة
231	طبيعة مشكلة الارتباط الذاتي
238	النتائج المترتبة على وجود مشكلة الارتباط الذاتي
239	إختبارات الارتباط الذاتي
244	بعض النواقص في إختبار درين — واطسن
244	الحلول لمشكلة الارتباط الذاتي
247	الفصل الحادي عشر / مشكلات الإنحدار / مشكلة عدم ثبات التباين
249	مقدمة
249	التفسير والعرض بصيغة شكل الإنتشار لثبات وعدم ثبات التباين
251	إمكانية وجود إفتراض تجانس التباين
253	النتائج المترتبة على وجود مشكلة عدم تجانس أو عدم ثبات تباين المتغير العشوائي (U)
254	إختبارات ثبات أو عدم تجانس التباين
258	الحلول لمشكلة عدم ثبات التباين
261	الفصل الثاني عشر / أسلوب المصفوفات في تحليل الإنحدار
263	مقدمة
263	المصفوفات
268	أمثلة إنحدار
269	تساوي المصفوفات
271	جمع وطرح المصفوفات

المحتويات

273	ضرب المصفوفات
277	أمثلة في إستخدام المصفوفات في تحليل الإنحدار
279	أنواع خاصة من المصفوفات
الصفحة	الموضوع
285	مثال على تحليل الإنحدار المتعدد بمتغيرين توضيحيين بإستخدام المصفوفات
290	بعض النظريات المهمة للمصفوفات
290	المتجهات والمصفوفات العشوائية
291	مصفوفة التباين والتباين المشترك للمتجه العشوائي
292	نموذج الإنحدار الخطي البسيط بصيغ المصفوفات
294	تقدير معلمات الإنحدار بطريقة المربعات الصغرى
296	تحليل التباين
301	الفصل الثالث عشر / نماذج المعادلات الآنية
303	مقدمة
304	طبيعة نماذج المعادلات الآنية
306	مثال على نماذج المعادلات الآنية
309	حل تحيز المعادلات الآنية
323	الفصل الرابع عشر / التشخيص الإحصائي
325	مقدمة
332	مشكلة التشخيص الإحصائي
347	الفصل الخامس عشر / تطبيقات وتمارين محلولة
349	بعض التمارين المحلولة
356	بعض التطبيقات الإقتصادية القياسية
363	المراجع

المقدمة

الحمد لله الذي مكنني من إتمام هذا العمل ، لقد كان مشروع تأليف كتاب في موضوع الإقتصاد القياسي أحد أهم أهدافي في عملي العلمي إذ بدأت أفكر في هذا المشروع منذ اليوم الأول الذي بدأت به تدريس هذا الموضوع عندما كنت أستاذاً في جامعة الموصل عام 1985 ولغاية عام 1997 ، و ثم في الجامعة المستنصرية منذ عام 1997 ولغاية عام 2002 ، ولكن الظروف كانت غير ملائمة لإنجاز هذا المشروع المهم . إن السبب الرئيس في إهتمامي بهذا المشروع هو الحاجة الماسة الى مصدر باللغة العربية يساعد الطلبة والباحثين في فهم هذا الموضوع وتطبيقاته بوصفه مادة علمية تتضمن منهجية نظرية وتجريبية مفيدة جداً في مجالات البحث العلمي في الإقتصاد .

إن هذا الكتاب ليس فقط كتاباً آخر في الإقتصاد القياسي ، إنه يغطي الموضوعات الأساسية في الموضوع ، وبخاصة تحليل الإنحدار البسيط والمتعدد وإستخدام المصفوفات في تحليل الإنحدار والتباين وعرضها بصيغة مناسبة ، وطرق المعادلات الآتية في تحليل الإنحدار ، ومن ناحية أخرى فقد تم إعطاء أهمية كبيرة لمشكلات الإنحدار وشرحها بقدر من التفصيل لأنها تكمل عملية دراسة تحليل الإنحدار .

يستهدف هذا الكتاب جمهوراً من طلبة الدراسات الجامعية الأولية والعليا في الإقتصاد والعلوم المالية والمصرفية فضلاً عن الباحثين في الشؤون والظواهر الإقتصادية ، إذ أصبح الإقتصاد القياسي من الموضوعات المهمة والشائعة بين الموضوعات الدراسية في الجامعات في العالم ، وذلك لأن هذا الموضوع يعد من أدوات البحث العلمي الأساسية ، والذي يربط بين نظرية الإقتصاد القياسي والجوانب التطبيقية على مستوى الواقع وهذا ما يجعل هذا الكتاب عاملاً وملائماً ومهماً .

إن هدفي الرئيس من كتابة هذا الكتاب هو أن يكون موضوع الإقتصاد القياسي مقرباً وممكن الفهم من قبل طلبة كليات الإقتصاد والعلوم الإدارية والباحثين ، لقد كتبت موضوعات هذا الكتاب على هدي فكرة التأكيد على الربط بين الأسس النظرية لعلم الإقتصاد القياسي وأهمها النظرية الإقتصادية ، والأدوات الرياضية والإحصائية ، وهذا الأسلوب هو الذي يحفز القاريء أو الطالب أو الباحث على التفكير بعمق أكثر لتطبيق تلك الأفكار والأدوات ، بمعنى إن هذا الأسلوب يعبر عن محاولة لدراسة علم الإقتصاد والظواهر الإقتصادية بين البعد النظري والبعد القياسي (التجريبي) .

ثمة إعتقاد في هذا الكتاب على موضوعات تشكل الركيزة الأساسية في الإقتصاد القياسي ، إذ إن هذا الكتاب يوفر إماماً جيداً بالمفاهيم والأسس النظرية لهذا الموضوع المهم ، وقد إنصرف التأكيد في هذا الكتاب على توفير التوضيح الملائم لمبادئ علم الإقتصاد القياسي مما يؤدي الى جعل الطالب يمتلك القدرة على إستعمال النماذج الإقتصادية القياسية في دراسته وتفسير نتائجها ، وبخاصة في مجال إعداد البحوث العلمية ، لقد سعت في جهدي هذا بقدر المستطاع أن أسلك طريقاً ملائماً وأكثر سلاسة وعملية في عرض المادة العلمية لهذا الموضوع ، جاعلاً هذا الجهد سبيلاً في توصيل المعرفة العلمية في هذا الموضوع وتسهيل عملية الفهم والإستيعاب لمضامينه ومفرداته من قبل الطالب أو الباحث .

أتمنى أن أكون قد وفقت في تقديم جهداً متواضعاً ومفيداً خدمة للتقدم العلمي والمسيرة العلمية في وطننا العربي .
والله ولي التوفيق

الفصل الأول
تعريف علم الإقتصاد القياسي

تعريف علم الإقتصاد القياسي

1-1 تعريف علم الإقتصاد القياسي .

تعرف كلمة القياس الإقتصادي (Econometrics) بأنها عملية القياس الإقتصادي (Economic Measurment) على الرغم من أن القياس يشكل جزءاً مهماً من الإقتصاد القياسي فإن مدى أو مجال الإقتصاد القياسي أوسع كثيراً من مجرد عملية القياس ، كما يبدو ذلك من النقاط الأساسية المتعلقة بتعريفات الإقتصاد القياسي :

1. إن الإقتصاد القياسي بوصفه نتيجة للنظر الى دور علم الإقتصاد يتألف من تطبيقات الإحصاء الرياضي (Mathematical Statistics) على البيانات الإقتصادية (Economic Data) لإعطاء الدعم التجريبي للنماذج التي بنيت في الإقتصاد الرياضي (Mathematical Economics) والحصول على نتائج رقمية (Numerical Results).

2. يمكن أن يعرف الإقتصاد القياسي بوصفه التحليل الكمي لظاهرة إقتصادية فعلية (Actual Economic Phenomena) ، تأسيساً على النظرية الإقتصادية والملاحظة وإستخدام طرقاً إحصائية للإستنتاج .

3. ويمكن أن يعرف الإقتصاد القياسي بأنه العلم الإجتماعي (Social Science) الذي يتم فيه تطبيق أدوات النظرية الإقتصادية والرياضيات والإستدلال الإحصائي على تحليل الظاهرة الإقتصادية .

4. يهتم علم الإقتصاد القياسي بالتقرير التجريبي (Emprical Determination) للقوانين الإقتصادية .

وهكذا فإن علم الإقتصاد القياسي يعرف بأنه العلم الذي يدرس العلاقات الإقتصادية بأسلوب كمي مستخدماً النظرية الإقتصادية والأسلوب الإحصائي والحقائق المعبر عنها بإحصاءات منقحة (Refined Data) ويعد علم الإقتصاد

القياسي أحد فروع علم الإقتصاد والتي تستخدم الأدوات الإحصائية والرياضية للحصول على قيم رقمية لمعاملات (Parameters) المتغيرات التي تعبر عن العلاقات الإقتصادية .

1-2 الإقتصاد القياسي بوصفه موضوعاً مستقلاً .

يعد علم الإقتصاد القياسي صياغة دقيقة من عناصر مثل النظرية الإقتصادية (Economic Theory) ، والإقتصاد الرياضي والإحصاء الإقتصادي (Economic Statistics) ، والإحصاء الرياضي (Mathematical Statistics) بوصفه خليط يكون شيئاً جديداً ، ولكن الإقتصاد القياسي موضوعاً يستحق أن يدرس مستقلاً بذاته للأسباب الآتية :

السبب الأول : إن النظرية الإقتصادية تضع عبارات وفرضيات غالباً ما تكون نوعية في طبيعتها ، مثلاً إن النظرية الإقتصادية الجزئية تقول إذا بقيت الأشياء الأخرى ثابتة فإن إنخفاض سعر سلعة معينة من المتوقع أن يؤدي الى زيادة الكمية المطلوبة من تلك السلعة ، وهكذا فإن النظرية الإقتصادية تتوقع علاقة سالبة أو علاقة عكسية بين السعر والكمية المطلوبة من السلعة ، ولكن النظرية نفسها لا تعطي أي قياس رقمي بين المتغيرين ، بمعنى أنها لاتخبرنا بالكمية التي تزداد بها الكمية المطلوبة نتيجة لتغيير معين في سعر السلعة ، إنها مهمة المختص بالإقتصاد القياسي (The Econometrician) أن يوفر تقديرات رقمية ، بعبارة أخرى تقول أن الإقتصاد القياسي هو الذي يعطي المحتوى التجريبي (Empirical Content) لمعظم النظرية الإقتصادية .

السبب الثاني : إن الإهتمام الرئيس للإقتصاد الرياضي هو التعبير عن النظرية الإقتصادية بشكل رياضي أي بصيغة معادلات (Equations) رياضية دون إعتبار لقابلية النظرية على القياس (Measurability) أو على التجريبية (Empirical) بينما نجد إن الإقتصاد القياسي يهتم بشكل رئيس بالإثبات

التجريبي (Empirical Verification) للنظرية الإقتصادية ، إن المختص بالإقتصاد القياسي غالباً ما يستعمل معادلات رياضية مقترحة من الإقتصاد الرياضي ، ولكنه يضع تلك المعادلات بشكل تسهل فيه عملية الإختبار التجريبي (Empirical Testing) وعملية التحويل للمعادلات الرياضية الى معادلات إقتصاد قياسي تتطلب الكثير من التأصيل والمهارة العلمية .

السبب الثالث : إن الإهتمام الرئيس للإحصاء الإقتصادي (Economic Statistics) هو في جمع وتمثيل وعرض البيانات الإقتصادية بشكل جداول وأشكال بيانية ، وهذا هو عمل المختص بالإحصاء الإقتصادي ، فهو المسؤول أولاً عن جمع بيانات عن الناتج القومي الإجمالي (GNP) ، وعن الإستخدام والبطالة والأسعار ، وغيرها من المتغيرات الإقتصادية ، وهكذا فإن هذه البيانات المجمعة تؤلف البيانات الخام للعمل الإقتصادي القياسي .

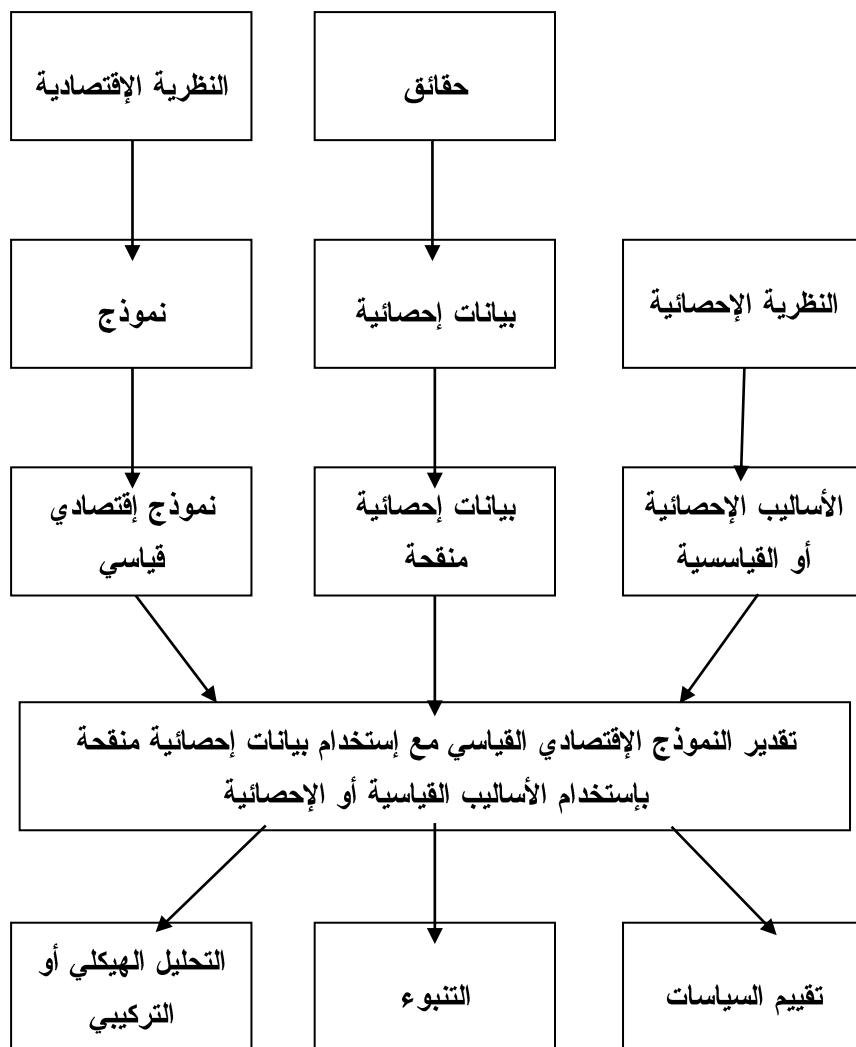
السبب الرابع : على الرغم من أن الإحصاء الرياضي (Mathematical Statistics) يوفر عدة أدوات تستخدم في مجالات معينة في الإقتصاد ، فإن المختص بالإقتصاد القياسي غالباً ما يحتاج الى طرق خاصة للنظر في الطبيعة الأحادية أو الفردانية لمعظم البيانات الإقتصادية ، بمعنى إن البيانات لا تخلق بوصفها نتيجة لتجربة مسيطر عليها ، فالمختص بالإقتصاد القياسي مثل المختص بالأنواء الجوية (Meteorologist) عموماً يعتمد على بيانات لا يمكن السيطرة عليها مباشرة ، وهكذا فإن بيانات حول الإستهلاك أو الدخل أو الإستثمار أو الإدخارات أو الأسعار ... الخ التي تجمع من قبل جهات عامة وخاصة هي ليست بيانات ناتجة عن تجربة .

إن المختص بالإقتصاد القياسي يأخذ هذه البيانات كما هي معطاة ، وهذه تخلق مشكلات خاصة لا يتم التعامل معها ضمن الإحصاء الإقتصادي ، والأكثر من هذا فإن مثل هذه البيانات من المحتمل أن تحتوي على أخطاء في

القياس ، مما يدعو المختص بالإقتصاد القياسي لتطوير طرقاً خاصة للتحليل للتعامل مع مثل تلك الأخطاء في القياس (Errors of Measurment) .

1-3 طبيعة علم الإقتصاد القياسي .

يستخدم علم الإقتصاد القياسي النظرية الإقتصادية والحقائق والأساليب الإحصائية (Statistical Techniques) .
تعد النظرية الإقتصادية واحدة من الأسس التي يعتمد عليها علم الإقتصاد القياسي في دراسته للظواهر الإقتصادية ، ويمكن توضيح طبيعة علم الإقتصاد بالشكل (1-1) الآتي :



شكل (1-1) يوضح طبيعة الإقتصاد

1-4 أغراض الإقتصاد القياسي (Purposes of Econometrics) .

1. التحليل الهيكلي أو التركيبي (Structural Analysis)

عند تقدير النموذج الإقتصادي القياسي يمكننا الحصول على قياسات كمية للعلاقات الإقتصادية المختلفة ، فضلاً عن تسهيل مهمة المقارنة بين النظريات المهمة التي تتعلق بظاهرة إقتصادية واحدة .

يعد التحليل الهيكلي واحداً من أهم الأغراض العلمية لعلم الإقتصاد القياسي ، وذلك لتسهيل مهمة فهم الظاهرة الإقتصادية في الحياة الواقعية بطريقة القياس الكمي والإختبار للتأكد من مصداقية العلاقات بين معدل التضخم (Validating Economic Relationships) والمثال على ذلك قياس العلاقة بين معدل التضخم (Inflation) ومعدل البطالة (Unemployment) ، أو ما يسمى بـ منحنى فيلبس (Phillips Curve) .

2. التنبؤ (Forecasting) .

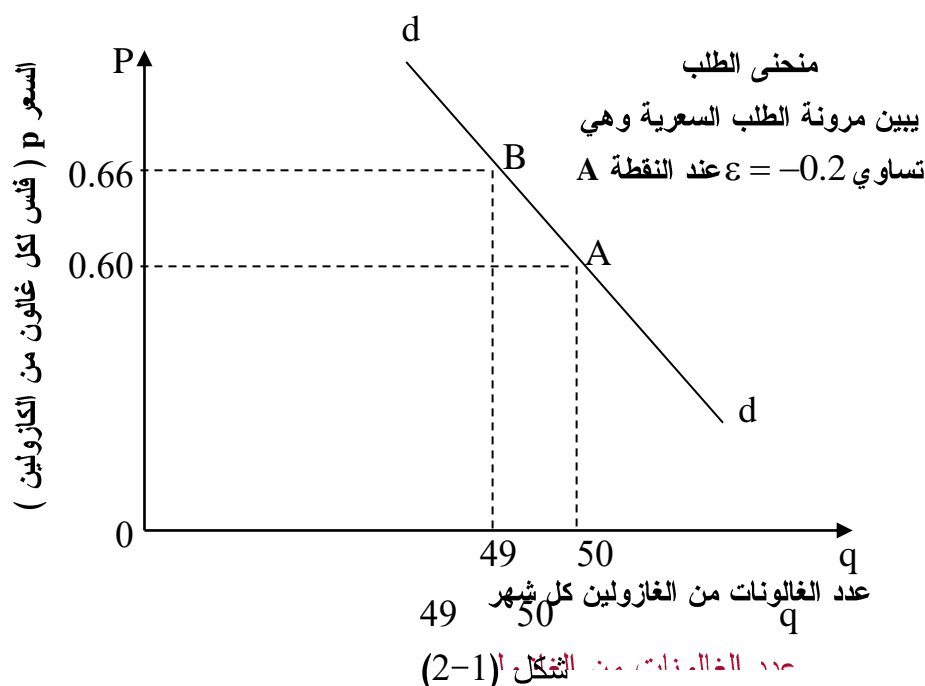
تستخدم نماذج الإقتصاد القياسي للتنبؤ عن طريق تقدير نموذج قياسي من أجل التنبؤ بالقيم الكمية لمتغيرات معينة لسنوات لاحقة في المستقبل وكمثال على التنبؤ شراء المواد الأولية ، وإستخدام عدد من العمال الإضافيين في شركة ما يعتمد على التنبؤ بأن المبيعات سوف تزداد خلال السنتين القادمتين أو أكثر وهكذا .

3. تقييم السياسات الإقتصادية (Policy Evaluation) .

تستخدم نماذج الإقتصاد القياسي للمفاضلة والإختبار بين السياسات الإقتصادية البديلة ، إن هذه الأغراض للإقتصاد القياسي هي أغراض متداخلة مع بعضها البعض .

مثال (1) منحني الطلب والمرونة السعرية .

إن واحداً من الأمثلة المهمة في دراسة الإقتصاد القياسي هو تقدير (Estimating) منحني الطلب لسلعة معينة مثل الكازولين ، إن الطلب على سلعة معينة بالنسبة للمستهلك يمكن توضيحها بالشكل الآتي :



إن الشكل أعلاه يبين العلاقة بين السعر والكمية المستهلكة حيث يمكن وضع هذه العلاقة بصيغة دالة (Function) ، ونقول أن الكمية من الكازولين (q) مقاسة بعدد الغالونات لكل شهر هي دالة للسعر (p) مقاساً بالفلس لكل غالون من الكازولين .

$$q = q(p)$$

إن النقاط كما في الشكل أعلاه للمثال الافتراضي عن منحني طلب المستهلك هي (A و B) في نقطة (A) سعر الكازولين كان (0.60) فلساً للغالون

الواحد لذلك ، فإن المستهلك الذي يعبر عنه منحنى الطلب في الشكل أعلاه هو (dd) سوف يشتري (50) غالوناً من الكازولين لكل شهر .

في نقطة (B) كل الأشياء بقيت على حالها ، ولكن سعر الكازولين إرتفع الى (0.66) فلساً للغالون الواحد ، فإن المستهلك سوف يشتري (49) غالون في الشهر الواحد ، إن المقياس المفيد الذي يعبر عن درجة إستجابة الكمية المطلوبة من سلعة معينة الى التغير في سعرها هو مقياس مرونة الطلب السعرية (Price elasticity of demand ϵ) التي تعرف أنها معدل التغير النسبي في الكمية المطلوبة الى التغير النسبي في السعر .

التغير النسبي في السعر في أي متغير مثل (z) هو معدل التغير في (z) وليكن (Δz) مقسوماً على المستوى الأساس لـ (z) ، وبعبارة أخرى $\frac{\Delta Z}{Z}$ وهكذا بالطريقة نفسها تكون مرونة الطلب السعرية مكتوبة بالشكل الآتي :

$$\epsilon = \frac{\Delta q/q}{\Delta p/p} = \frac{p}{q} \cdot \frac{\Delta q}{\Delta p}$$

مرونة الطلب هذه تسمى مرونة الطلب السعرية وهي على نحو عام سالبة ، ومن خلال الأرقام الموجودة في الشكل (1-2) ، فإن مرونة الطلب السعرية في نقطة (A) تكون تقريباً :

$$\epsilon = \frac{\Delta q/q}{\Delta p/p} = \frac{50}{0.66-0.60} \cdot \frac{0.10}{60} = \frac{-0.02}{0.10}$$

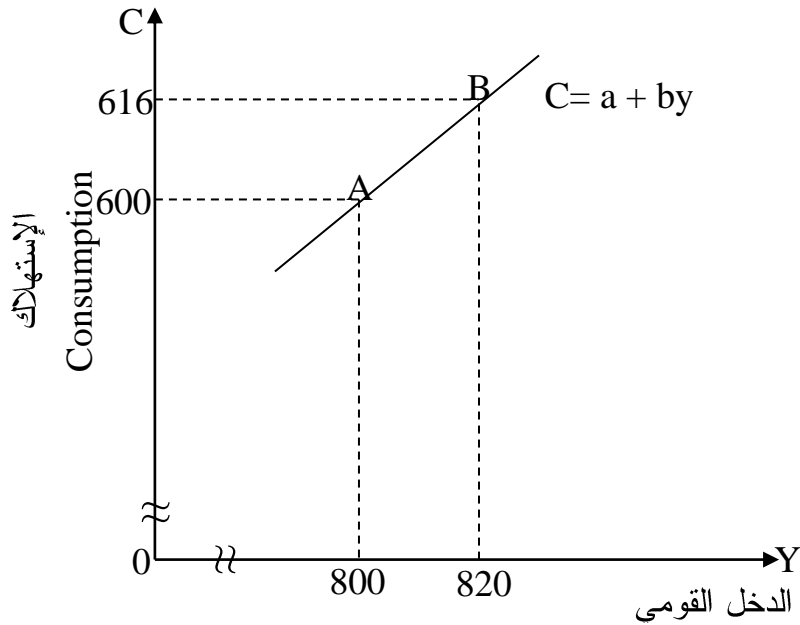
وهكذا في نقطة (A) فإن 10% زيادة في سعر الغالون من الكازولين سوف تقلل الكمية المطلوبة بنسبة 2% تقريباً . إن تقدير مرونة الطلب السعرية لسلع معينة أو خدمات معينة هو مثال على دراسة الإقتصاد القياسي .

إن هذه الدراسة تجمع بين النظرية الإقتصادية معبر عنها بنموذج منحنى الطلب والحقائق معبر عنها بالأرقام المتعلقة بالسعر والكمية والأسلوب المستخدم هو معادلة المرونة .

إن المقاييس الرقمية ، التي تحصل لدرجة إستجابة الكمية المطلوبة للسعر هي مهمة جداً لأغراض التحليل الهيكلي أو البنوي ، كما أنها مفيدة لأغراض التنبؤ وتقييم السياسات الإقتصادية ، وكمثال التنبؤ عن إستيراد السنة القادمة من المواد الخام أو المواد الطبية أو الكيماوية للسنة القادمة .

مثال (2) حول دراسة الإقتصاد القياسي .

دالة الإستهلاك (The Consumption Function) في هذا المثال من دراسة الإقتصاد القياسي تقوم بتقدير دالة الإستهلاك والتي تعد من العناصر الأساسية في بناء النماذج الإقتصادية الكلية التي تقرر الإستهلاك الكلي للإقتصاد الوطني بوصفه دالة في الدخل الكلي .



شكل (1-3)

الشكل (3-1) يوضح دالة إستهلاك خطية وفيها قيمة الإنفاق الإستهلاكي الكلي (C) بالدينار بوصفه دالة في قيمة الدخل القومي بالدينار (Y) (يعني GNP) ، دالة الإستهلاك على نحو عام هي عبارة عن منحنى صاعد ، ولكن إنحدارها (Slope) هو أقل من واحد (1) ، بمعنى إن الإضافة الى الدخل تؤدي الى الإضافة للإستهلاك ، ولكن أيضاً تؤدي الى إضافة للإدخارات ، وميل منحنى دالة الإستهلاك هو الميل الحدي للإستهلاك (MPC) (Marginal propensity to consume) ، وهذا الميل من المفروض أن يكون موجباً ، ولكن أقل من (1) ، وهكذا في هذه الحالة تكون دالة الإستهلاك الخطية كالآتي :

$$C = a + by \quad 0 < b = MPC < 1$$

من النقطتين الموجودتين في الشكل (3-1) فإن (MPC) الميل الحدي للإستهلاك يمكن تقديره بالطريقة الآتية :

$$\frac{\Delta C}{\Delta Y} = \frac{616-600}{820-800} = 0.8$$

إن الـ (0.8) تتضمن إن (800) فلساً من كل دينار يضاف الى الدخل يذهب الى الإستهلاك .

مرة أخرى نجد أن هذا المثال حول قياس الميل الحدي للإستهلاك (MPC) يمثل دراسة إقتصادية تجمع بين النظرية الإقتصادية (دالة الإستهلاك) والبيانات حول الدخل القومي والإستهلاك الكلي مع أسلوب إقتصادي قياسي عن طريق معدل التغيير في الإستهلاك على معدل التغيير في الدخل القومي ، إن هذا القياس مهم في فهم تركيب أو هيكل الإقتصاد الكلي ، وكذلك في التنبؤ بمستويات الدخل الكلي أو الاستخدام في المستقبل وكذلك تحليل السياسات الإقتصادية المقترحة مثل السياسة النقدية (Monetary Policy) والسياسة المالية (Fiscal Policy) .

1-5 ما هو النموذج (What is the model) .

النموذج (Model) تعريفاً هو أي تعبير عن ظاهرة فعلية (Actual phenomenon) ، مثل نظام فعلي أو طريقة معينة ، إذ إن الظاهرة الفعلية أو الحقيقية يعبر عنها بالنموذج من أجل توضيحها والتنبؤ بها والسيطرة عليها ، وهذا يذكرنا بأغراض الإقتصاد التي تضمنت التحليل الهيكلي (Structural Analysis) ، والتنبؤ (Forecasting) ، وتقييم السياسات (Policy Evaluation) ، في بعض الأحيان فإن النظام الفعلي يدعى نظام العالم الواقعي (Real – World System) ، وذلك من أجل التمييز بين النظام الفعلي (العالم الحقيقي) ، ونظام النموذج الذي يعبر عنه .

إن فن بناء النماذج هو جزء مكمل لمعظم العلوم بغض النظر عن كونها علوم صرفه (physical) أو علوم إنسانية (Social) وذلك لأن أنظمة العالم الحقيقي التي نحن بصددنا معقدة على نحو كبير بطبيعتها ، فالنظام قد يكون الكترون يتحرك في معجل أو أسعار تنظم في أسواق مختلفة ، أو تقرير الدخل القومي ، في هذه الحالات من الأنظمة أو غيرها ، فإن ظاهرة العالم الحقيقية معقدة جداً ، وهذا يتطلب التعامل مع هذه الظاهرة بتعبيرات مبسطة عن طريق النماذج (Models) .

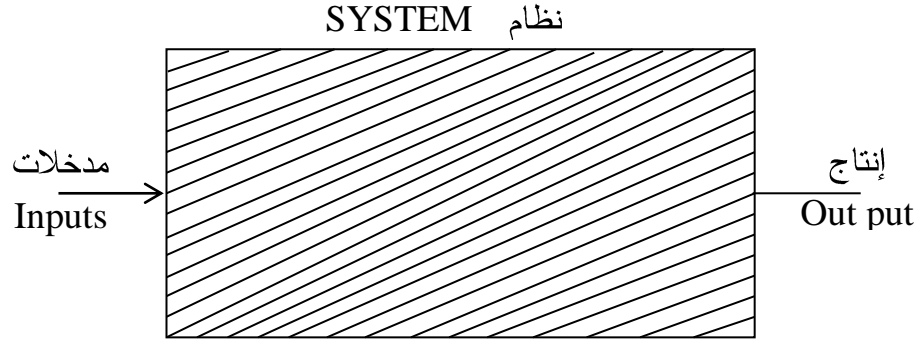
إن أي نموذج يحاول أن يوفق (compromise) بين الحقيقة أو الواقع ، وبين إمكانية التعبير أو إمكانية العمل مع النموذج فضلاً عن إن النموذج يجب أن يكون تعبيراً معقولاً عن نظام الواقع أو العالم الحقيقي ، وبهذا المعنى يجب أن يكون واقعياً (Realistic) في جمع العوامل الرئيسة للظاهرة المراد التعبير عنها ، ومن جانب آخر يجب أن يكون النموذج ممكن العمل به أو معه (Manageable) في أنه ينتج أو يلقي الأضواء على هذه الظاهرة ، أو ينتج معلومات غير ممكن الحصول عليها من الملاحظة أو المراقبة المباشرة للنظام الواقعي .

إن الحصول على إمكانية جيدة للعمل مع النموذج يتطلب عادةً طرق مختلفة لتشذيب أو تهذيب النموذج والتي تشتمل على حذف المؤثرات الخارجية كذلك تبسيط العمليات ، إن عملية التشذيب عادةً تجعل النموذج أقل تطابقاً مع الواقع ، ولكن هذه العملية ضرورية للتأكد من أن النظام أو نظام النموذج أصبح من الممكن التعامل معه وإستخدامه على نحو معقول .

وهكذا فإن التوازن الملاءم بين الواقع أو الحقيقة وإمكانية العمل أو إمكانية إستخدام النموذج هو جوهر عملية بناء النموذج الجيد ، ولذلك فإن النموذج الجيد (Good Model) هو النموذج القريب من الواقع وفي الوقت نفسه ممكن العمل به وإستخدامه ، هذا النموذج يحدد العلاقات المتداخلة بين أجزاء النظام للظاهرة بطريقة مفصلة ما فيه الكفاية وواضحة ، وذلك للتأكد من إن دراسة النموذج تؤدي الى معلومات تتعلق بنظام العالم الحقيقي ، والنموذج يكون رديئاً عندما يعبر عن الواقع على نحو معقد ، وعندئذ يكون من الصعب التعامل معه وإستخدامه للحصول على المعلومات ، في هذه الحالة فإن مبرر بناء النموذج يصبح معدوماً أو غير وارد بالدرجة الأولى ، والنوع الآخر من النماذج الرديئة يذهب الى تطرف من الجانب الآخر ، أي بمعنى الإبتعاد عن الواقع بمسافة شاسعة ، على نحو يبتعد فيه عن العوامل المهمة في نظام العالم الحقيقي ويحذفها ، وفي هذه الحالة فإن عملية تشذيب النموذج قد ذهبت بعيداً أو تم التركيز عليها على نحو يؤثر على نتائج النموذج وذلك لأن التأثيرات التي يستبدها النموذج هي مهمة جداً ، إن مثل هذا التطرف على درجة عالية من الخطورة لأنه يوصلنا الى نتائج غير ملائمة ولا تعبر عن حقيقة الحال في الظاهرة الواقعية .

الى هذا المدى نجد أنه من المستحيل أن نصل وعلى نحو دقيق الى كيفية بناء النموذج الجيد ، إذ إن بناء النماذج هو عملية يعد جزءاً منها فناً والجزء الآخر يعد علماً ، إن حالة التطرف تدعى " الصندوق الأسود "

(Black Box) ، في الشكل (1-4) ، إذ لم تبذل أية محاولة لإعادة إنتاج الواقع، أو بعبارة أخرى التعبير عن الواقع على نحو تفصيلي ، في هذه الحالة فإن النموذج يعبر عن العوامل الداخلة في النظام دون إعتبار النظام نفسه .



الصندوق الأسود (Black – Box) يصف التلفزيون كمثال ويتعرف على تيار الكهرباء الذي يصل الى التلفزيون ونقاط وعلامات السيطرة عن طريق نقطة التشغيل ، وكذلك البرامج التي تقدم على الشاشة ، الصندوق الأسود يعالج الدواخل والخارج (Inputs and Outputs) دون المحاولة لتحليل كيف ترتبط الدواخل بالخارج .

إن عملية بناء النموذج عادةً تبدأ مع الصندوق الأسود وبعد ذلك يوضح ما موجود في داخل الصندوق ، إذاً النموذج الأولي هو عبارة عن نموذج الصندوق الأسود الذي يعالج العوامل الداخلة في الصندوق (Inputs) ، والعوامل الخارجة منه (Outputs) فقط وفي بعض الأحيان يسمى النموذج الوصفي (Descriptive Model) ولكن متابعة العوامل الداخلة في النظام أو الصندوق بعد دخولها في النظام ومتابعة النواتج الخارجة قبل خروجها من النظام أو الصندوق تؤدي الى نماذج موضحه أكثر وفي النهاية ينتج نموذج تحليلي (Analytic Model) ، أي يصبح الصندوق أبيض (White – Box) الذي يعالج بوضوح التداخل بين العوامل الداخلة والنواتج .

وكمثال فإن نموذج الصندوق الأبيض للتلفزيون يعبر عنه بالدائرة الكهربائية الكاملة ، لذلك فإن عملية بناء النموذج عبارة عن محاولة مستمرة لتشكيل نماذج تحليلية قادرة على تحليل مختلف حالات التداخل للنظام الحقيقي .

1-6 أنواع النماذج (Types of Models) .

ثمة أنواع عدة من النماذج موجودة في العلوم المختلفة ومن بين الأنواع الأكثر أهمية هي النماذج الكلامية المنطقية (Verbal \ Logical Models) النماذج الفيزيائية (Physical Model) ، والنماذج الهندسية (Geometric Models) والنماذج الجبرية (Algebraic Models) .
أولاً : النماذج المنطقية / الكلامية .

تستعمل هذه النماذج التشبيه اللفظي أو الكلامي في العلوم التي تعتمد على التحقيق (Inquiry) .

إن هذا النوع يستعمل التشبيه مثل الإستعارة أو المجاز والنموذج الناتج بعض الأحيان يدعى الفكرة الشاملة (paradigm) عن حالة معينة ، في علم الإقتصاد هناك مثلاً فكرتين شاملتين الأولى طورت من قبل آدم سميث (Adam Smith) وهي فكرة تقسيم العمل التي تتضمن أن كل فرد ينجز الأعمال التي يمتلك فيها مهارة أو ميزة نسبية .

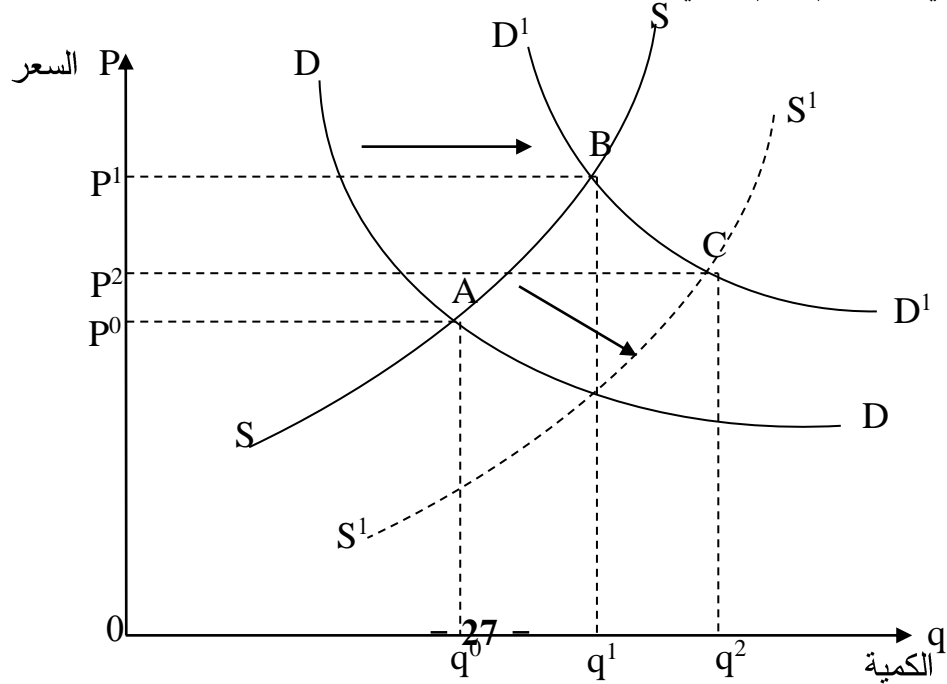
وهكذا يقسم العمل على هذا الأساس مما يؤدي الى زيادة الإنتاج ، إن هذه الفكرة من الممكن تطبيقها على مستوى الإقتصاد القومي أو الدولي ، إستخدم آدم سميث النموذج الكلامي أو الوصفي ، إذ ناقش هذه الفكرة مشيراً الى معمل إنتاج الدبابيس وتقسيم العمل فيه بوصفه نموذجاً لتوضيح فكرة تقسيم العمل .

والفكرة الثانية التي قدمها آدم سميث هي فكرة اليد الخفية (Invisible Hand) التي تتضمن إن الأفراد في سعيهم لتحقيق مصالحهم فإنهم

دون أن يشعروا يحققون مصلحة المجتمع في وضع ضمن نظام السوق ، إذ نجد في نظام الأسعار الحرة كل وحدة من وحدات الإقتصاد وتقاد في نشاطها عن طريق نظام من علامات التغيير في الأسعار ، وهنا يشبه آدم سميث هذه الحالة بوجود يد خفية توجه كل القرارات التي يصنعها الأفراد بإتجاه الرفاه العام للمجتمع .

ثانياً : النماذج الهندسية (Geometric Models) .

تعد النماذج الهندسية من النماذج ذات الأهمية العظيمة في تطور النظرية الإقتصادية . إذ يتم التعبير عن العلاقات الإقتصادية هندسياً ، ومن أجل أن نبين أهمية هذا النوع من النماذج نشير الى إن معظم كتب النظرية الإقتصادية تستخدم هذا النوع من النماذج والنموذج الهندسي يستخدم المنحنيات والرسوم البيانية الأخرى لتوضيح العلاقات بين المتغيرات ، إن واحداً من الأمثلة المهمة على النموذج الهندسي هو النموذج الذي يستخدم في تقرير السعر في سوق واحدة معزولة ، إذ يمكن الحصول على هذا النموذج عن طريق جمع منحنى الطلب للسوق الواحدة مع منحنى العرض لصناعة واحدة مثل ما موجود في الشكل (4-1) الآتي :



شكل (4-1)

إن منحنى الطلب في السوق هو (DD) يوضح الكمية المطلوبة من السلعة أو الخدمة في مستويات متعددة من الأسعار ، ومنحنى عرض الصناعة (SS) يوضح الكميات المعروضة من السلعة في مستويات بديلة أو متعددة من الأسعار ، تعبر النقطة (A) عن وضع التوازن بين طلب السوق وعرض الصناعة ، بمعنى أنه في نقطة (A) نحصل على التوازن عندما تكون قرارات الشراء من قبل المستهلكين منسجمة مع قرارات البائعين (المنتجين) ، وهكذا فإن الشكل (1-4) يوضح كيفية الوصول الى سعر التوازن وكمية التوازن في سوق واحدة عندما تتقاطع المنحنيات .

أما التغيرات التي تحصل في المتغيرات الأخرى عدا السعر يمكن أخذها في الحسبان عن طريق السماح للمنحنيات بالإنقال أو الحركة ، على سبيل المثال إرتفاع دخل المستهلك أو إنخفاض أسعار السلع المكمل للسلعة في مثالنا ربما يؤدي الى إنقال منحنى الطلب الى الخارج الى (D^1D^1) ، في حالة مثل هذا الإنقال في منحنى الطلب يكون المطلوب أكثر من السابق ، عند النقطة (A) سيكون هنالك زيادة في الطلب أكثر من المعروض من السلعة وهذا يؤدي الى وجود طلب غير مشبع (Unsatisfied Demand) ، وهكذا يضع ضغطاً على السعر نحو الإرتفاع ، ونقطة التوازن الجديدة هي (B) .

من جانب العرض ، فإن الحركة أيضاً تشمل حركة منحنى العرض أو إنقال منحنى العرض ، مثلاً ينتقل منحنى العرض نحو الخارج الى (SS^1) ، وهنا نجد عرضاً أكثر ، إن نقطة التوازن في السعر مع إنقال المنحنيين نحو الخارج أصبحت نقطة (C) .

ثالثاً : النماذج الجبرية (Algebraic Models)

تعد النماذج الجبرية لأغراض الإقتصاد القياسي من النماذج الأكثر أهمية ، إذ إنها تعبر عن الواقع بوساطة نظام من المعادلات ، ومن الأمثلة على هذه النماذج ، نموذج دالة الإستهلاك الذي بوساطته يتم تقرير قيم التوازن للإستهلاك الكلي والدخل القومي .

$$C = Y (Y) \text{-----}(1-1)$$

$$Y = C + Z \text{-----}(1-2)$$

عندما يكون (Y) هو الدخل القومي (C) الإستهلاك الكلي (Z) الإنفاق الحكومي . يتميز النموذج الجبري عن النموذج الهندسي في أن النموذج الجبري يمكننا وبسهولة إضافة متغيرات جديدة الى معادلاته ، ويقرر النموذج الجبري قيم متغيرات معينة تدعى المتغيرات الداخلية (Endogenous Variables) وهي متغيرات معتمدة تقرر قيمتها آنياً بوساطة علاقات النموذج الجبري ، في هذه الحالة فإن الإستهلاك الكلي والدخل القومي هما من المتغيرات الداخلية ، والذي نريده هو توضيحها والتنبؤ عن قيمها . يحتوي النموذج الجبري أيضاً على متغيرات أخرى تدعى المتغيرات الخارجية (Exogenous Variables) ، والتي تقرر قيمها خارج نظام النموذج ولكنها تؤثر على قيم المتغيرات الداخلية . فهي تؤثر على نظام المعادلات ولكنها لا تتأثر بذلك النظام . يحتوي النموذج ايضاً على معلمات (Parameters) معينة ، والتي تقدر على نحو عام عن طريق أساليب الإقتصاد القياسي بإستخدام الإحصاءات الملاءمة .

رابعاً : النموذج الإقتصادي القياسي (Econometric Model)

يمكن إعتبار نموذج الإقتصاد القياسي نوعاً خاصاً من النماذج الجبرية . أولاً إن النموذج الإقتصادي القياسي هو نموذج إحتمالي (Stochastic Model) يحتوي على واحد أو أكثر من المتغيرات العشوائية (Random Variables) ، كذلك فهو يعبر عن نظام من العلاقات الإحتتمالية (Stochastic Relations) بين المتغيرات الداخلة في النظام ، وثانياً فإن

النموذج الإقتصادي القياسي هو إما نموذج خطي أو نموذج غير خطي ، إن فرضية كون النموذج خطي هي من الفرضيات المهمة جداً ، والمثال على النموذج الإقتصادي القياسي هو النموذج الذي يحتوي على معلمات في المعادلة الآتية :

$$C = a + by \text{-----}(1-3)$$

عندما يكون $C =$ الإستهلاك الكلي ، $Y =$ الدخل الكلي ، $a, b =$ معلمات (b) تعبر عن الميل الحدي للإستهلاك .

من الخصائص المهمة التي يتصف بها النموذج الإقتصادي القياسي هي أن النموذج إحصائي وهذا النموذج يحتوي على متغيرات عشوائية على عكس النموذج التقريري (Deterministic Model) الذي لا يحتوي على متغيرات عشوائية ، إن المعادلة (1-3) تعطينا مستوى الدخل (Y) ومستوى الإستهلاك (C) مقرر تماماً بقيمة $(a + by)$ ، وهذا غير مقبول أو غير منطقي ، وذلك لأن هناك عوامل أخرى بجانب الدخل يمكن أن تؤثر على الإستهلاك مثل الأسعار ، الذوق ، الثروة الخ ، لذلك يجب أن يقدر الإستهلاك (C) عند مستوى معطى من الدخل (Y) كمعدل $(a + by)$ ، وعلى نحو عام فإن الإستهلاك سيكون ضمن قيم عليا وقيم دنيا أي :

$$C = a + by \pm \Delta \text{-----}(1-4)$$

وهنا فإن (ϵ) توضح مستوى أعلى أو أدنى من قيمة المعدل جبرياً أما الطبيعة العشوائية للعلاقة عادةً يعبر عنها في حالة دالة الإستهلاك :

$$C = a + by + \epsilon$$

إن (ϵ) تعبر عن الخطأ أو الحد العشوائي (Stochastic Disturbance Term) الذي يلعب دور آلية الصدفة (Chance Mechanism) ، إن النموذج الإقتصادي القياسي إما يكون ساكناً أو

حركياً ، فالنموذج الساكن (Static) لا يعتمد على عامل الزمن ، بينما النموذج الحركي فإن الوقت يلعب دوراً أساسياً فيه .

7-1 أنواع العلاقات الاقتصادية

أ- العلاقات السلوكية (Behavioral Relations)

لنأخذ دالة الإستهلاك كمثال وهي :

$$C = a + by \text{ ----- (1-5)}$$

إن هذه الدالة تعبر عن علاقة سلوكية ، إذ إنها تصف كيف يتصرف المستهلكون على مستوى المعدل ، آخذين بنظر الاعتبار مجموع مصروفاتهم على السلع والخدمات وبعد معرفة حجوم دخولهم .

ب- العلاقات التعريفية (Definitional Relations)

إن هذه العلاقات تعبر عنها المتطابقات كالاتي :

القيمة بالدينار للسلعة أو الخدمة = الكمية × السعر

التغيير في خزين رأس المال = الإستثمار الصافي

ج- العلاقات الساكنة والحركية (Static & Dynamic Relations)

في هذه العلاقات ، إذا كان كلاً من المتغيرين (C) و (Y) يتعلقان بالسنة نفسها أو الفترة نفسها ، فإن مثل هذه العلاقة تسمى علاقة ساكنة ، ولكن عندما يعتمد الإستهلاك ليس فقط على الدخل في السنة الحالية وإنما يعتمد أيضاً على الدخل في السنة السابقة ، فإننا نستطيع أن نضع المعادلة بالشكل الاتي :

$$C_t = a + b_1 Y_t + b_2 Y_{t-1} \text{ (1-6)}$$

إن المعادلة (1-6) هي مثال يعبر عن علاقة سلوكية حركية وذلك لأنها تحتوي على متغيرات تعود الى تواريخ مختلفة .

8-1 منهجية البحث العلمي في الاقتصاد القياسي

Methodology of Econometrics

لتوضيح منهجية الإقتصاد القياسي لنأخذ النظرية الكينزية في الإستهلاك

يقول كينز (Keynes) :

" إن القانون النفسي الأساسي إن الرجل والمرأة يميلان كقاعدة وعلى مستوى المعدل الى زيادة إستهلاكهم كلما يزداد الدخل ، ولكن ليس بالنسبة نفسها لزيادة الدخل " ، وبإختصار يقول كينز ان الميل الحدي للإستهلاك (MPC) (Marginal Propensity to Consume) وهو معدل التغير في الإستهلاك نتيجة للتغيير بوحدة واحدة مثلاً دينار من الدخل ، وهو أي (MPC) أكبر من الصفر (0) وأقل من 1 (1) $0 < MPC < 1$ ، ولإختبار هذه النظرية فإن المختص بالإقتصاد اياسي سيقوم بالإجراءات الآتية :

1-8-1 تحديد النموذج الإقتصادي القياسي

Specification of The Econometric Model

على الرغم من إن كينز يعرض العلاقة الموجبة بين الإستهلاك والدخل ولكنه لم يحدد الشكل الدالي الدقيق للعلاقة بين المتغيرين ، ولغرض التبسيط فإن الإقتصاد الرياضي ربما يقترح علينا الشكل الآتي لدالة الإستهلاك الكينزية :

$$Y = \alpha + \beta X \dots\dots\dots (1-7)$$

عندما يكون (Y) = الإنفاق الإستهلاكي ، (X) = الدخل ، (α, β) = ثوابت أو معلمات ، إن معلمة الميل (β) تعبر عن الميل الحدي للإستهلاك (MPC) .

تنص المعادلة (1-7) على إن الإستهلاك يرتبط خطياً بالدخل هي مثال على النموذج الرياضي (Mathematical Model) ، فالنموذج هو عبارة عن منظومة أو مجموعة من المعادلات الرياضية : فإذا إحتوى النموذج على معادلة واحدة ، كما في المثال السابق فإنه يدعى نموذج المعادلة الواحدة (a single equation model) ، بينما إذا إحتوى النموذج على أكثر من معادلة واحدة فإنه يعرف بأنه نموذج متعدد المعادلات

(Multi equation Model) ، أو نموذج معادلات آنية (Simultaneous – equation Model) .

إن النموذج الرياضي الصافي لدالة الإستهلاك الذي تمثله المعادلة (1-7) محدود الاستخدام من قبل المختص بالإقتصاد القياسي ، وذلك لأن هذا النموذج يفترض وجود علاقة تامة (Exact Relationship) أو علاقات تقريرية (Deterministic Relationship) بين الإستهلاك والدخل . ولكن العلاقات بين المتغيرات الإقتصادية هي عموماً غير تامة (Inexact) . وهكذا إذا حصلنا على بيانات حول الإنفاق الإستهلاكي (Y) والدخل تحت التصرف (X) (بعد طرح الضريبة) لعينة مؤلفة من (5000) عائلة ، ورسمنا هذه البيانات على ورق مربعات مع وضع الإنفاق الإستهلاكي على الإحداثي العمودي والدخل تحت التصرف على الإحداثي الأفقي ، فإننا سوف لن نتوقع أن كل المشاهدات الـ (5000) أن تقع تماماً على الخط المستقيم للمعادلة (1-7) ، وهذه الحالة تعود الى أنه فضلاً عن الدخل تحت التصرف هناك متغيرات أخرى تؤثر على الإنفاق الإستهلاكي ، على سبيل المثال حجم العائلة ، وأعمار أعضاء العائلة ، وديانة العائلة... الخ كل هذه المتغيرات تمارس تأثيراً على الإستهلاك العائلي .

وللتعبير عن العلاقات غير التامة (Inexact) بين المتغيرات الإقتصادية فإن المختص بالإقتصاد القياسي سوف يحور دالة الإستهلاك التقريرية (1-7) كما يأتي :

$$Y = \alpha + \beta X + U \dots \dots \dots (1-8)$$

عندما يكون $U =$ حد الإضطراب أو حد الخطأ (Error Term) وهو متغير عشوائي (Random Variable) أو متغير إحتتمالي (Stochastic Variable) وهو متغير بصفات إحتتمالية معروفة جيداً ، إن حد

الإضطراب (U) ربما يعبر عن كل تلك القوى التي تؤثر على الإستهلاك ، ولكنها لم تؤخذ في الحساب صراحة (Explicitly) .

إن المعادلة (1-8) تعبر عن مثال للنموذج الإقتصادي القياسي وبصيغة فنية فإن المعادلة (1-8) هي مثال على نموذج الانحدار الخطي (A Linear Regression Model) ، إن دالة الإستهلاك (1-8) في الإقتصاد القياسي تعبر عن الفرضية التي تقول إن المتغير المعتمد (Y) الإستهلاك يرتبط خطياً بالمتغير التوضيحي (X) (Explanatory Variable) الدخل ولكن العلاقة بين المتغيرين غير تامة ، إنها خاضعة للانحراف الفردي .

2-8-1 التقدير (Estimation)

بعد تحديد النموذج فإن الخطوة اللاحقة في العمل الإقتصادي القياسي هي الحصول على تقديرات (Estimates) قيم رقمية لمعاملات النموذج من البيانات المتوفرة ، وهذه البيانات يمكن أن تجهز من الإحصاء الإقتصادي ، وهكذا في دراسة لدالة الإستهلاك الكينزية المعطاة سابقاً وجد ان $\beta = 0.8$. إن هذه القيمة الرقمية ليس فقط توفر تقديراً رقمياً للميل الحدي للإستهلاك (MPC) ، ولكن أيضاً تدعم فرضية كينز التي تقول إن الـ (MPC) أقل من (1) ، إن الحصول على تقديرات لـ β ، α سيكون من خلال دراسة الانحدار (تحليل الانحدار) .

3-8-1 الإثبات (Verification)

الإستدلال الإحصائي (Statistical Inference)

بعد الحصول على تقديرات المعلمات β ، α فإن الخطوة اللاحقة هي تطوير معيار ملائم لإيجاد في ما إذا كانت المعلمات المقدرة بالنموذج تتطابق مع التوقعات من النظرية الإقتصادية . وكما لاحظنا سابقاً توقع كينز أن (MPC) موجبة ولكنها أقل من (1) ، إفتراض أنه في دراسة لدالة

الإستهلاك ، وجد أن $MPC = 0.9$ ، على الرغم من هذا التقدير رقمياً هو أقل من (1) ولكن الباحث لابد أن يعرف في ما إذا كان التقدير دون الواحد ما فيه الكفاية لإقناعنا إن هذه النتيجة ليست نتيجة حصلت بالصدفة في عملية أخذ العينة . بعبارة أخرى ، هل إن هذا التقدير (estimate) إحصائياً أقل من واحد ؟ فإذا كان أقل من (1) فإنه يدعم وجهة نظر كينز ، وإذا كان أكثر من (1) فإنه يدحض رؤية كينز .

إن مثل هذا الإثبات أو الدحض (Refutation) للنظريات الاقتصادية على أساس الدلائل التجريبية يتأسس على فرع من فروع النظرية الإحصائية يدعى الاستدلال الإحصائي (Statistical Inference) أو اختبار الفرضيات (Hypothesis Testing) .

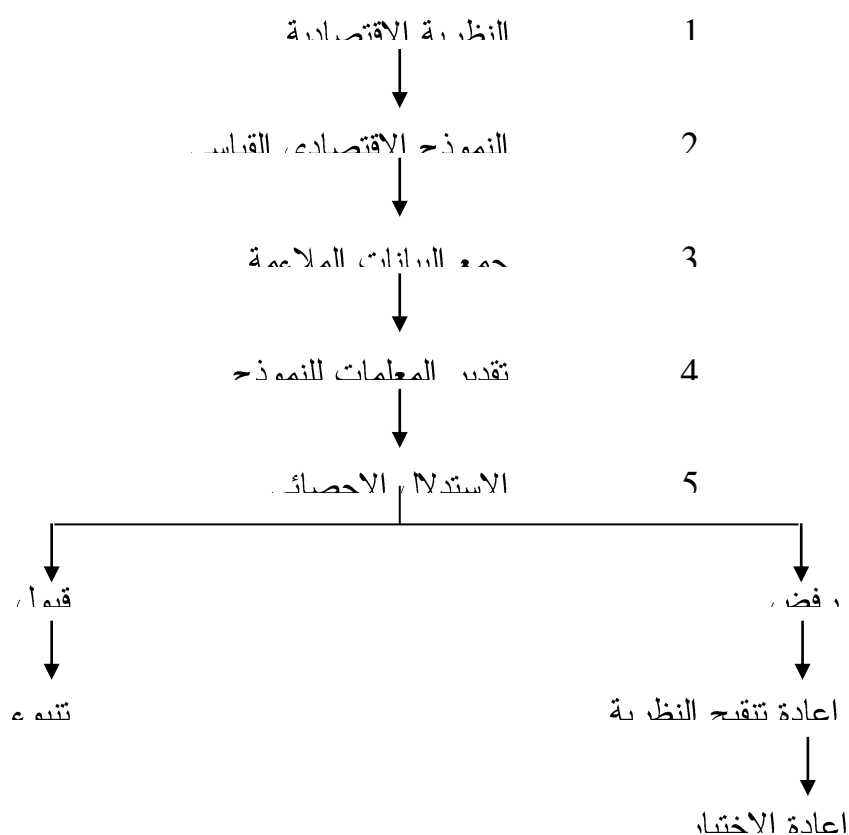
4-8-1 التنبؤ (Forecasting)

غالباً ما يستخدم النموذج الاقتصادي القياسي المقدر لأغراض التنبؤ بقيم مستقبلية للمتغير المعتمد على أساس قيم معروفة أو متوقعة في المستقبل للمتغير المستقل ، مثلاً يفترض إن الحكومة تقوم بتخفيض في ضريبة الدخل الفردية أو الشخصية من أجل حفز الاقتصاد القومي ، ما هو التأثير الذي سوف تحدثه هذه السياسة على الإنفاق الاستهلاكي ، ولذلك على الاستخدام والدخل ، وكما تبين نظرية الاقتصاد الكلي فإن التغيير في الإنفاق الاستهلاكي الذي ينتج بعد تغيير بمقدار دينار واحد في الدخل يكون معطى بوساطة مضاعف الإستهلاك (Consumption Multiplier) (M) الذي يعرف كما يأتي :

$$M = \frac{1}{1 - MPC}$$

إذا كان $MPC = 0.8$ فإن (M) سيكون (5) ، بمعنى إذا إزداد الدخل بدينار واحد فإن ذلك سيقود الى زيادة خمسة مرات (Fivefold) في الإنفاق الإستهلاكي ، إن القيمة الحاسمة في هذا الحساب هو مضاعف الإستهلاك الذي

يعتمد على قيمة (MPC) . وهكذا فإن التقدير الكمي لـ (MPC) يوفر معلومات قيمة لأغراض السياسة ، فإذا عرفنا (MPC) نستطيع التنبؤ بالإستهلاك في المستقبل بعد تغييرات في سياسة الحكومة المالية .
وهكذا فإن التحقيق الإقتصادي القياسي عموماً يكون كما يأتي :



1-9 أنواع الإقتصاد القياسي

عموماً فإن الإقتصاد القياسي يمكن أن ربما يقسم الى فئتين :

1- الإقتصاد القياسي النظري (Theoretical Econometrics)

2- الإقتصاد القياسي التطبيقي (Applied Econometrics)

الأول يهتم بتطوير الطرق الملائمة لقياس العلاقات الإقتصادية المحددة بواسطة نماذج الإقتصاد القياسي ، وفي هذا الإعتبار فإن الإقتصاد القياسي يعتمد على نحو كبير على الإحصاء الرياضي (Mathematical Statistics) .
أما في الإقتصاد القياسي التطبيقي فإننا نستعمل أدوات الإقتصاد القياسي النظري لدراسة حقول خاصة في الإقتصاد مثل دالة الإنتاج ودالة الإستهلاك ودالة الإستثمار ودوال العرض والطلب الخ .

الفصل الثاني

نظرية الارتباط

نظرية الارتباط

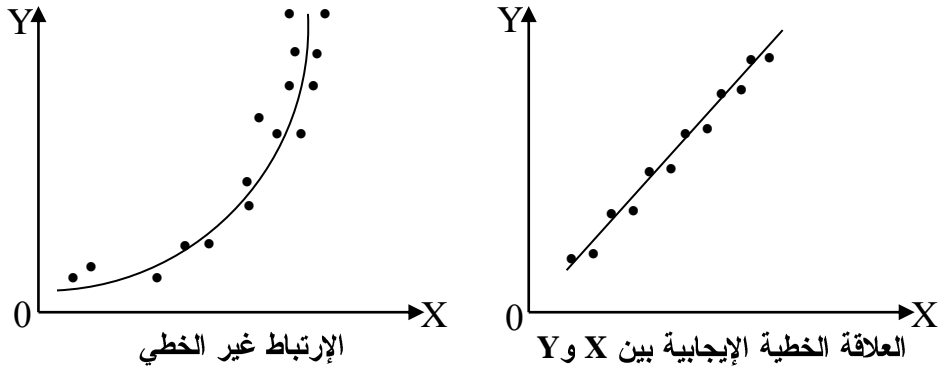
1-2 مقدمة

ثمة طرق مختلفة لقياس العلاقات الموجودة بين المتغيرات الاقتصادية ومن أبسط هذه الطرق هي طريقة تحليل الارتباط (Correlation Analysis) وطريقة تحليل الانحدار (Regression Analysis)، يجب أن نبدأ من تحليل الارتباط وذلك على الرغم من أن تحليل الارتباط يعاني من محددات خطيرة عديدة، فضلاً عن أنه يلقي ضوءاً بسيطاً على طبيعة العلاقة الموجودة بين المتغيرات، ولكنه من ناحية أخرى يجعل القارئ أو الطالب على معرفة جيدة بمعامل الارتباط الذي يعد من المقاييس الإحصائية المهمة في تحليل الانحدار. يعرف الارتباط بأنه درجة العلاقة الموجودة بين متغيران أو أكثر، إن درجة العلاقة الموجودة بين متغيرين تسمى ارتباط بسيط (Simple Correlation)، ودرجة العلاقة التي تربط ثلاث متغيرات أو أكثر تسمى ارتباط متعدد (Multiple Correlation)، سيتم التركيز في هذا الفصل على الارتباط البسيط فقط، تاركين مناقشة الارتباط المتعدد إلى فصل آخر بعد مناقشة تحليل الانحدار (والحقيقة أن معامل الارتباط المتعدد لا يمكن تفسيره أو دراسته من دون دراسة تحليل الانحدار المتعدد).

ربما يكون الارتباط خطياً عندما تكون نقاط (Y, X) في الشكل البياني أو شكل الانتشار (Scatter Diagram) تبدو متركزة قرب خط مستقيم، أو غير خطي (Non-Linear) عندما تكون نقاط (Y, X) تبدو واقعة قرب منحنى إن متغيرين إثنين ربما يكون لهما ارتباط إيجابي أو ارتباط سلبي أو ربما ليس لهما ارتباط (Uncorrelated)، وهذا الشيء نفسه يصح بالنسبة للعلاقة الخطية وغير الخطية.

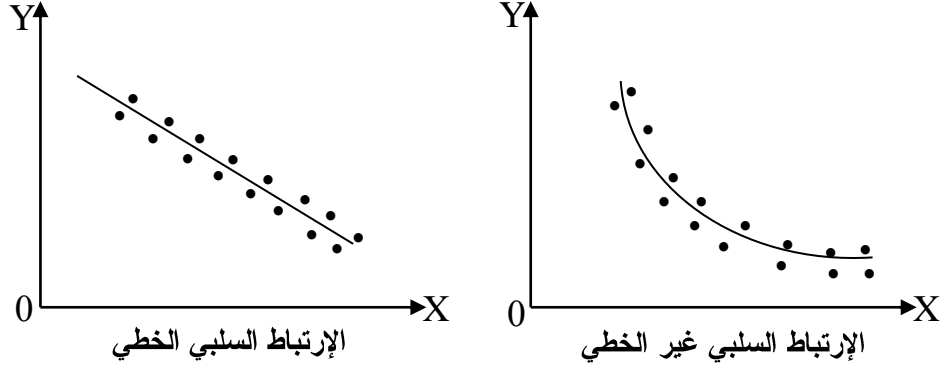
1-1-2 الارتباط الإيجابي (Positive Correlation) .

إذا كان هناك متغيرين مرتبطين إيجابياً ، فإن ذلك يعني أن كلاً من المتغيرين يميلان إلى التغيير في الاتجاه نفسه أي أن المتغيرين يميلان للتغيير معاً وفي الاتجاه نفسه ، وهذا يعني أنهما يميلان إلى الزيادة والنقصان معاً ، إن مثل هذا الارتباط الإيجابي تفترضه النظرية الإقتصادية في علاقة عرض السلعة من الكميات مع سعر السلعة في السوق ، عندما يزداد السعر فإن الكمية المعروضة تزدد وبالعكس عندما ينخفض السعر فإن الكمية المعروضة تنخفض أيضاً ، وكما موضح في الشكل الآتي (1-2) :



2-1-2 الارتباط السلبي (Negative Correlation) .

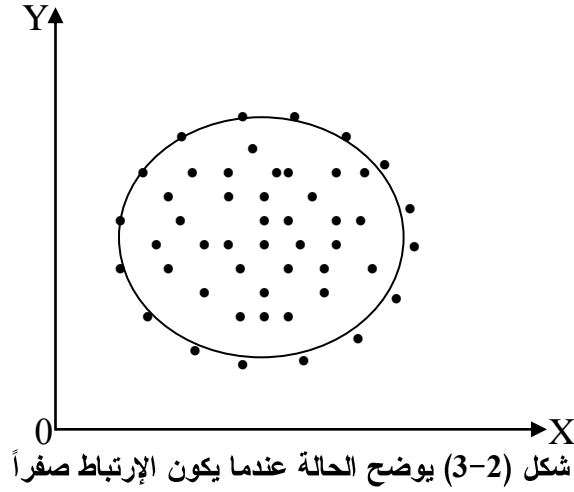
إن متغيرين يقال أنهما مرتبطان سلبياً إذا كانا يميلان للتغيير باتجاه معاكس : أي عندما يزداد (X) فإن (Y) ينخفض والعكس بالعكس ، مثلاً الكمية المطلوبة من السلعة وسعرها يرتبطان سلبياً ، فعندما يزداد السعر فإن الطلب على السلعة ينخفض ، وعندما ينخفض السعر فإن الطلب على تلك السلعة يزداد والشكل البياني الآتي (2-2) يوضح أن نقاط (X و Y) تتمركز حول خط مستقيم أو منحنى بميل سالب ، فإذا كانت كل نقاط (X و Y) تقع على الخط المستقيم أو المنحنى فإن الارتباط هو ارتباط سلبي تام .



شكل (2-2)

3-1-2 عدم الارتباط (No Correlation, or Zero Correlation) .

إن متغيرين غير مرتبطين مع بعضهما عندما يميلان للتغيير مع عدم الارتباط ببعضهما ، وكما توضح في الشكل البياني (3-2) الآتي أو شكل الانتشار (Scatter Diagram) .



إن النقاط لـ (X, Y) منتشرة على سطح المستوى لـ (X, Y) مثلاً نقول إن الارتباط صفراً بين وزن الطلبة ولون شعرهم .

2-2 قياس الارتباط الخطي (Measure of Linear Correlation) .

1-2-2 معامل الارتباط الحقيقي (إرتباط المجتمع الإحصائي

The population correlation Coefficient (P) ومعامل الارتباط المقدر

للعيينة (r) Sample Estimate .

على ضوء المناقشة السابقة يبدو أنه بإمكاننا أن نقرر نوع الارتباط بين متغيرين بوساطة المشاهدة المباشرة للرسم أو الشكل البياني ، فضلاً عن أن الرسم البياني يوضح قوة العلاقة بين متغيرين ، فإذا وقعت النقاط قريبة من الخط المستقيم ، فإن الارتباط يكون قوياً ، من ناحية أخرى فإن التشتت العظيم (dispersion) في النقاط حول الخط يتضمن ارتباطاً ضعيفاً ، من الملاحظ أن فحص الشكل البياني يعطينا فكرة مبسطة أو صورة تقريبية للعلاقة بين المتغيرين (x و y) .

من أجل الحصول على قياس دقيق لدرجة العلاقة أو الارتباط بين المتغير (X) والمتغير (Y) نستعمل معامل يدعى معامل الارتباط (The Correlation Coefficient) ، وعادةً يرمز له بالحرف الأغريقي (P) إن الحرف (P) يشير إلى كل القيم أو المجتمع الإحصائي (population) للمتغيرين (X) و (Y) ، إن تقدير (P) من أية عينة إحصائية (Sample) يدعى بـ (r) ، مثلاً إذا كنا نقيس الارتباط بين (X) و (Y) فإن معامل ارتباط المشاهدة الكلية أو المجتمع الإحصائي يعبر عنه بـ (P_{XY}) وتقديره من العينة الإحصائية يعبر عنه بـ (r_{XY}) معامل الارتباط في العينة ، يمكن كتابته على النحو الآتي :

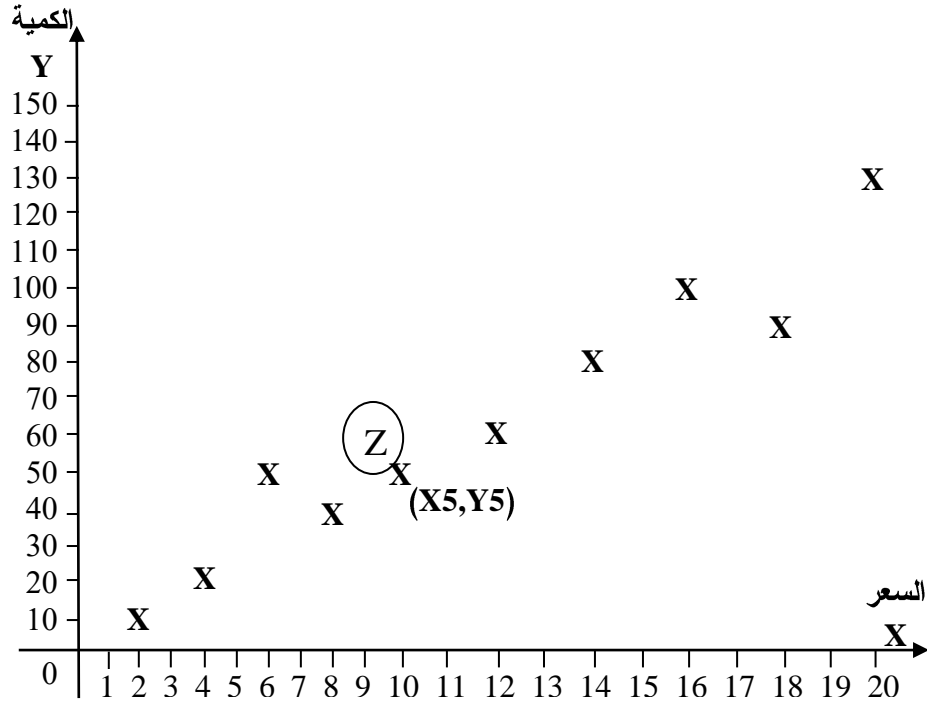
$$r_{XY} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2} \sqrt{\sum (y_i - \bar{y})^2}}$$

سوف نستخدم مثلاً بسيطاً من نظرية العرض (Supply Theory) توضح النظرية الإقتصادية أن الكمية المعروضة من السلعة في السوق تعتمد على سعرها مع بقاء الأشياء الأخرى ثابتة (Ceteris paribus) عندما يزداد السعر فإن الكمية المعروضة تزداد وبالعكس ، وعندما ينخفض السعر فإن المنتجين يعرضون كميات أصغر من سلعهم للبيع ، بعبارة أخرى إن النظرية الإقتصادية ترى إن السعر (X) والكمية المعروضة (Y) مرتبطان إيجابياً .

إن مشكلتنا هنا أن نعرف المقياس الذي سنستخدمه لتقدير الارتباط بين السعر (X) والكمية المعروضة (Y) ، واجبنا الأول هو جمع المشاهدات (الأسعار والكميات المعروضة خلال مدة معينة من الزمن) ، بعض البيانات الإفتراضية تبدو في الجدول (1-2) الآتي :

السعر بالدينار	الكميات المعروضة بالكغم	المدة الزمنية بالأيام
X_i	Y_i	
2	10	1
4	20	2
6	50	3
8	40	4
10	50	5
12	60	6
14	80	7
16	90	8
18	90	9
20	120	10
$\sum_{i=1}^n X_i = 110$	$\sum_{i=1}^n Y_i = 610$	$N=10$

عندما نضع هذه البيانات بصيغة شكل الإنتشار (Scatter Diagram) نحصل على الشكل البياني (2-4) ، وذلك من أجل أن نعرف هل أن العلاقة خطية (Linear) أو غير خطية (Non Linear) .



شكل (2-4)

إن كل نقطة في شكل الانتشار تعبر عن زوج من السعر والكمية في مدة زمنية معينة على سبيل المثال النقطة (Z) تعبر عن زوج (X₅, Y₅) وهي النقطة التي يكون فيها السعر عشرة دنانير والكمية المعروضة (50) كغم خلال المدة الخامسة ، ومن النظر الى شكل الانتشار ، نرى أن النقاط تميل الى الإستقطاب حول خط ذو ميل موجب ، وهذا يثبت أن هناك إرتباط خطي إيجابي بين السعر والكمية ، من أجل إيجاد المقياس التام للإرتباط نعمل كما يأتي :

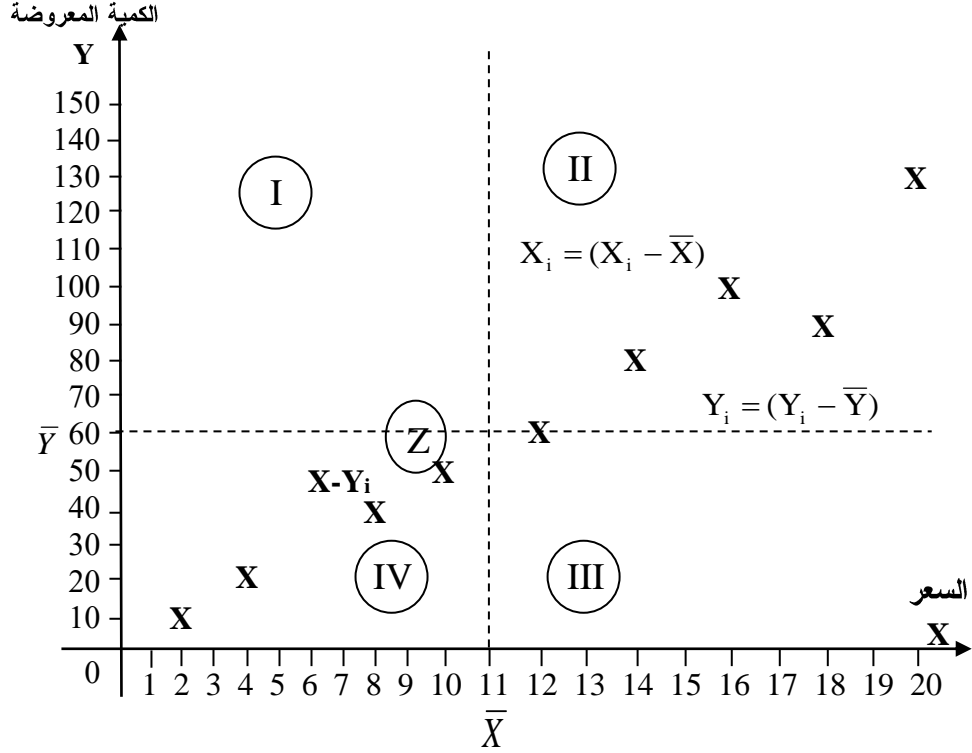
1- نحسب كمية الوسط الحسابي (Mean) للمتغيرات .

$$61 = \frac{610}{10} = \frac{\sum Y_i}{n} = \bar{Y}$$

$$11 = \frac{110}{10} = \frac{\sum X_i}{n} = \bar{X}$$

2- نرسم الأعمدة $\bar{X}\bar{X}$ ، $\bar{Y}\bar{Y}$ من الوسط الحسابي \bar{X} والوسط الحسابي \bar{Y}

وهكذا نقسم المساحة الى أربعة أرباع I,II,III,IV في الشكل (2-5) الآتي :



3- بعدها نأخذ إنحرافات قيم X و Y عن الوسط الحسابي لـ X و Y

والإشارة الى هذا الاختلاف بالحروف الصغيرة وكما يأتي :

$$xi = (Xi - \bar{X})$$

$$yi = (Yi - \bar{Y})$$

إن نتيجة هذه العملية في إختيار الإنحرافات لقيم المتغيرات X و Y عن

الوسط الحسابي ، يمكن أن تزودنا بمقياس للارتباط بين المتغير (X) والمتغير

(Y) .

(a) في الربع الثاني (II)، والربع الرابع (IV) فإن :

الناتج $(Xi - \bar{X})(Yi - \bar{Y}) = xiyi$ موجباً ، وذلك لأن للانحرافين $(Xi - \bar{X})$ و $(Yi - \bar{Y})$ الإشارة نفسها إما موجبة أو سالبة .

(b) في الربع الأول (I)، والربع الثالث (III) فإن ناتج الانحرافات

$(Xi - \bar{X})(Yi - \bar{Y}) = xiyi$ سالباً لأن للانحرافات إشارات الواحدة عكس الأخرى.

وهكذا إذا كان أغلب المشاهدات (البيانات) تقع في الربع الثاني (II)

والربع الرابع (IV) ، فإن الارتباط بين (X, Y) يكون موجباً ، وإذا كانت معظم

النقاط للسعر والكمية تقع في الربع الأول (I) والربع الثالث (III) ، فإن

الارتباط بين (Y, X) سيكون سالباً ، وإذا كانت المشاهدات أو النقاط منتشرة

على نحو عشوائي في كل الأرباع أو الأجزاء الأربعة ، فإن القيم الموجبة والقيم

السالبة لـ $(xiyi)$ ستلغي بعضها البعض ومجموع النتائج يمثل الإقتراب من

الصفر ، فإذا كان مجموع ناتج الانحرافات للمتغيران $(Y)(X)$ عن وسطهما

الحسابي هو قيمة موجبة فإن الارتباط بين (X) و (Y) سيكون موجباً ، بينما إذا

كان مجموع ناتج الانحرافات سالباً فإن الارتباط بين $(Y), (X)$ سيكون سالباً :

$$\sum_i^n (Xi - \bar{X})(Yi - \bar{Y}) = \sum_i^n xiyi > 0$$

الارتباط بين $(Y), (X)$ موجباً .

$$\sum_i^n (Xi - \bar{X})(Yi - \bar{Y}) = \sum_i^n xiyi < 0$$

الارتباط بين $(Y), (X)$ سالباً .

وهكذا فإن ناتج مجموع الانحرافات $(\sum xiyi)$ يزودنا بمقياس للعلاقة

$(Y), (X)$ ولكن هذا القياس له خللين :

الأول : إن هذا المقياس يؤثر عليه عدد المشاهدات الداخلة . كلما كان

عدد المشاهدات كبيراً كلما كان عدد الناتج أكبر ولذلك فإن مجموع $(\sum xiyi)$

سيكون مختلفاً . وهكذا إذا كان $(Y), (X)$ مرتبطان إيجابياً ، فإن أي زيادة في عدد المشاهدات سوف تجعل الارتباط يبدو قوياً بدون أن يكون ذلك صحيحاً بالضرورة .

الثاني : إن المجموع $(\sum x_i y_i)$ يتأثر بوحدات القياس للمتغيرات $(Y), (X)$ مثلاً الارتباط في المثال السابق سوف يبدو أكبر إذا كان العرض مقاساً بالكيلوغرام والسعر بالفلس حتى لو كانت المشاهدات أي العدد نفسه من المشاهدات .

لتصحيح الخلل الأول نقوم بتقسيم المجموع $(\sum x_i y_i)$ على عدد المشاهدات (n) .

$$\frac{\sum x_i y_i}{n} = S_{x_i y_i}$$

إن S_{xy} هو التباين المشترك (Covariance) بين (X) و (Y) من الواضح انه مقياس أفضل للارتباط من المجموع البسيط $(\sum x_i y_i)$ وذلك لأنه سوف يتغير مباشرة مع عدد المشاهدات في العينة (Sample) ولكن مع هذا يبقى المقياس يعاني من خلل لأنه يتأثر بالوحدات التي تقاس بها المتغيرات $(Y), (X)$ ومن أجل تصحيح هذا الخلل نقوم بتقسيم التباين المشترك (Covariance) على الانحرافات المعيارية (Standard deviations) للمتغيرات التي تقاس بالوحدة نفسها التي تقاس بها المتغيرات التي تكون أو تصبح النسبة رقم صافي مستقل عن أي تغيير في وحدات قياس $(Y), (X)$ ، إن النسبة الناتجة هي معامل ارتباط العينة (r) الذي هو تقدير لمعامل ارتباط المشاهدات أو المجتمع الإحصائي (P) .

$$r = \frac{\sum_i^n x_i y_i}{n S_x S_y} = \frac{S_{YX}}{S_X S_Y}$$

$$S_{xy} = (Y), (X) \text{ التباين المشترك لـ} = \frac{\sum XIYI}{n}$$

الانحراف المعياري لـ (X) S_x

$$S_x = \sqrt{\frac{\sum (XI - \bar{X})^2}{n}} = \sqrt{\frac{\sum xi^2}{n}}$$

الانحراف المعياري لـ (Y) S_y

$$S_y = \sqrt{\frac{\sum (Yi - \bar{Y})^2}{n}} = \sqrt{\frac{\sum yi^2}{n}}$$

نعوض عن قيم S_y, S_x, S_{xy} في معادلة (r) نجد :

$$r = \frac{\sum xiyi}{n \sqrt{(\frac{\sum xi^2}{n})(\frac{\sum yi^2}{n})}} = \frac{\sum xiyi}{\sqrt{(\sum xi^2)(\sum yi^2)}} \dots\dots(1-2)$$

هذه المعادلة وضعت بصيغة الانحرافات للمتغيرات $(Y), (X)$ عن

وسطيهما الحسابي ، أما إذا أردنا أن نستخدم القيم الفعلية للملاحظات فإننا

نستخدم الشكل الآتي للمعادلة :

$$r = \frac{n \sum (XiYi) - (\sum Xi)(\sum Yi)}{\sqrt{n \sum Xi^2 - (\sum Xi)^2} \sqrt{n \sum Yi^2 - (\sum Yi)^2}} \dots\dots(2-2)$$

هذا الشكل للمعادلة مشتق من المعادلة السابقة عن طريق التحويلات

الآتية :

$$r = \frac{\sum xiyi}{\sqrt{\sum xi^2} \sqrt{\sum yi^2}}$$

1- البسط (Numerator) يمكن توسيعه كما يأتي :

$$\begin{aligned}\sum x_i y_i &= \sum (X - \bar{X})(Y - \bar{Y}) = \sum (XY - Y\bar{X} - X\bar{Y} + \bar{X}\bar{Y}) \\ &= \sum XY - \bar{X} \sum Y - \bar{Y} \sum X + n\bar{X}\bar{Y} \\ &= \sum XY - \frac{\sum X}{n} \sum Y - \frac{\sum Y}{n} \sum X + n \frac{\sum X}{n} \frac{\sum Y}{n} \\ &= \frac{n \sum XY - \sum X \sum Y}{n} \dots\dots\dots(3-2)\end{aligned}$$

2- من المقام في المعادلة (1-2) حصلنا على :

$$\begin{aligned}\sum x_i^2 &= \sum (X_i - \bar{X})^2 = \sum (X_i^2 - 2X\bar{X} + \bar{X}^2) \\ &= \sum X_i^2 - 2\bar{X} \sum X + n\bar{X}^2 \\ &= \sum X_i^2 - 2\bar{X} \sum X + nX \frac{\sum X_i}{n} \\ &= \sum X_i^2 - 2\bar{X} \sum X_i + \bar{X} \sum X \\ &= \sum X_i^2 - \bar{X} \sum X_i \\ &= \sum X^2 - \frac{\sum X_i}{n} \sum X_i \\ &= \sum X^2 - \frac{(\sum X)^2}{n} \dots\dots\dots(4-2) \\ &= \frac{n \sum X_i^2 - (\sum X_i)^2}{n} \dots\dots\dots(5-2)\end{aligned}$$

وبالطريقة نفسها نستطيع أن نجد قيمة $\sum y_i^2$ للمتغير Y

$$\sum y_i^2 = \frac{n \sum Y^2 - (\sum Y)^2}{n} \dots\dots\dots(6-2)$$

3- نعوض عن المعادلة (3-2)(4-2)(6-2) في المعادلة (1-2) نجد أن :

$$r = \frac{\{n \sum XY - (\sum X)(\sum Y)\} / n}{\sqrt{\frac{\{n \sum X^2 - (\sum X)^2\}}{n}} \sqrt{\frac{\{n \sum Y^2 - (\sum Y)^2\}}{n}}}$$

$$r = \frac{n \sum XY - (\sum X)(\sum Y)}{\sqrt{n \sum X^2 - (\sum X)^2} \sqrt{n \sum Y^2 - (\sum Y)^2}}$$

إن القانون المذكور أعلاه لمعامل الارتباط له فائدتين :

1- القانون متشابه بالنسبة الى (X) و (Y) وهذا يعني أن $r_{xy} = r_{yx}$

2- القانون أعلاه يطبق فقط في حالات العلاقات الخطية .

2-2-2 القيم الرقمية لمعامل الارتباط

إن معامل الارتباط هو مقياس لدرجة التغير المتزامن للمتغيرات مع

بعضها البعض (Covariability) (X) و (Y) .

إن القيم التي يتخذها معامل الارتباط بين 1- الى 1+ عندما يكون (r)

موجباً فإن المتغير (X) و (Y) يتغيران بالاتجاه نفسه زيادة أو نقصاناً معاً ،

وعندما يكون (r = 1+) فهذا يعني أن يتضمن أن هناك ارتباط تام إيجابي بين

(X) و (Y) .

وبالرسم البياني فإن كل المشاهدات عن (X) و (Y) تقع على خط مستقيم

مع ميل موجب كما في الشكل (7-2) عندما يكون معامل الارتباط (r) سالباً فإن

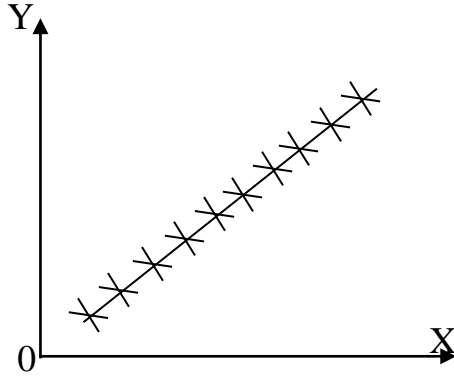
(X) و (Y) يتحركان باتجاهات متعاكسة ، فإذا كان $r = 1-$ فإن هذا يعني أن

هناك علاقة ارتباط سالبة تامة موجودة بين المتغيرين (X) و (Y) وبالشكل

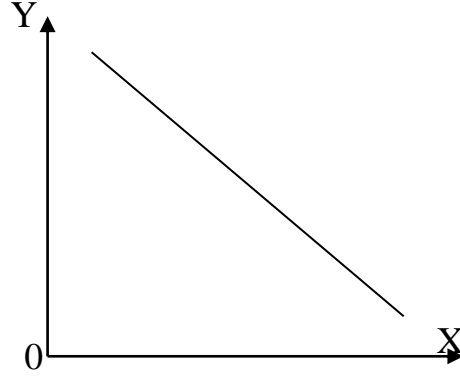
البياني كل المشاهدات عن (X) و (Y) تقع على خط مستقيم مع ميل سالب كما

في الشكل (6-2) وعندما يكون (r) مساوياً للصفر فإن المتغيرين غير مرتبطين

(Uncorrelated) .



شكل (7-2)



شكل (6-2)

في التطبيق العملي سوف لا نلاحظ حالة الارتباط التام أو حالة عدم الارتباط ، عادة فإن (r) يأخذ قيمة بين الصفر والواحد ، كلما كانت قيمة (r) قريبة من قيمة (1) فإن درجة الارتباط تكون كبيرة وإن النقاط قريبة أو تقترب من الخط المستقيم في الشكل البياني ، من ناحية أخرى كلما كانت النقاط مبعثرة في الشكل البياني كلما إقترب الارتباط بين المتغيرين من الصفر .

نقول أن (r) هو معامل الارتباط المقدر من العينة لمعامل الارتباط للمجتمع الإحصائي (P)(population Correlation) . إن (r) بوصفه تقديراً إحصائياً حتماً معرض لبعض الأخطاء ويجب أن يختبر من ناحية درجة الاعتماد إحصائياً .

مثال : لنفترض أننا نريد أن نحسب معامل الارتباط بين المتغير (Y)(الكمية المعروضة) و (X)(السعر) مع المشاهدات العطاءة في الجدول (1-2):

حساب معامل الارتباط (r) بإستعمال الإنحرافات عن الوسط الحسابي

$$r = \frac{\sum x_i y_i}{\sqrt{\sum x_i^2} \sqrt{\sum y_i^2}}$$

في هذا المثال نريد حساب قيم $\sum xi^2$ ، $\sum yi^2$ ، $\sum xiyi$ الموجودة في القانون أعلاه : $\sum xi^2 = 330$ و $\sum xiyi = 1810$ و $\sum yi^2 = 10490$ وبالتعويض نجد أن :

$$r = \frac{1810}{\sqrt{330} \sqrt{10490}} = 0.975$$

حساب معامل الارتباط باستخدام أو استعمال البيانات الفعلية :

$$r = \frac{n \sum XiYi - \sum Xi \sum Yi}{\sqrt{n \sum X^2 - (\sum X)^2} \sqrt{n \sum Y^2 - (\sum Y)^2}}$$

من القانون نجد أننا بحاجة الى حساب القيم الآتية :

$$\sum Xi^2 \quad \sum Yi^2 \quad \sum Xi \quad \sum Yi \quad (\sum Xi)^2 \quad (\sum Yi)^2 \quad \sum XiYi$$

$$r = \frac{(10)(8.520) - (610)(110)}{\sqrt{(10)(1540) - 12100} \sqrt{(10)(47.700) - 372100}}$$

$$r = 0.975$$

2-3 معامل ارتباط الرتب (The Rank Correlation Coefficient).

إن معامل الارتباط الخطي الذي قمنا بدراسته في النقطة السابقة يعتمد على فرضية أن المتغيرات الداخلة في العلاقة هي متغيرات كمية ، ولدينا بيانات دقيقة من أجل قياس تلك المتغيرات . ولكن في حالات عدة ربما تكون المتغيرات نوعية (Qualitative Variables) ولذلك لا يمكن قياسها بالأرقام (numerically) ، مثلاً المهنة والتعليم والتفضيلات لنوع معين وغيرها من المتغيرات النوعية ، فضلاً عن أنه في حالات عدة فإن قيماً دقيقة للمتغيرات ربما لا تكون موجودة ، لذلك فإنه من المستحيل حساب قيمة معامل الارتباط

مع القانون الذي ذكرناه في النقطة السابقة ، في مثل هذه الحالة من الممكن أن نستخدم مقياس إحصائي آخر وهو معامل ارتباط الرتب أو ما يسمى بـ معامل ارتباط سبيرمان (Spearman Correlation Coefficient) نقوم بترتيب المشاهدات أو البيانات في تتابع محدد مثلاً حسب الحجم أو الأهمية الخ مستعملين الأرقام 1، 2، 3، n بعبارة أخرى نحن نعطي رتب (Ranks) للبيانات الإحصائية ونقيس العلاقة بين الرتب بدلاً من القيم الفعلية ، لذلك أصبح إسم المقياس الإحصائي معامل ارتباط الرتب ، فإذا كان لدينا متغيرين (y,x) مرتبان بطريقة يكون فيها معامل ارتباط الرتب محسوب بالقانون الآتي :

$$r' = \frac{6\sum D^2}{n(n^2-1)}$$

عندما يكون

D = الفرق بين الرتب المرافقة لكل زوج من (y,x) .

n = عدد المشاهدات

إن قيمة (r¹) تكون (1+)(1-) يجب ملاحظة نقطتين مهمتين عند تطبيق معامل ارتباط الرتب :

أولاً - من الممكن أن يتم ترتيب المشاهدات تصاعدياً أو تنازلياً ، ولكن يجب أن تستخدم قواعد الترتيب نفسها بالنسبة للمتغيرين (y,x) .

ثانياً - إذا كان هناك متغيرين أو أكثر لهما القيمة نفسها نعطي لهما معدل الرتب ، والمثال الآتي يوضح تطبيق معامل ارتباط الرتب .

مثال : الجدول الآتي يوضح كيف أن عشرة طلاب قد رتبوا إستناداً الى درجة أدائهم في العمل الصفي ، وإمتحانهم النهائي ، نريد أن نعرف هل أن هناك علاقة بين أداء الطلبة خلال السنة كلها وأدائهم في إمتحاناتهم النهائية :

طلبة	A	B	C	D	E	F	G	H	I	J
الترتيب على أساس العمل الصفي	2	5	6	1	4	10	7	9	3	8
الترتيب على أساس درجات الإمتحان	1	6	4	2	3	7	8	10	5	9

الحل :

الفرق بين الرتب يوضح في الجدول الآتي :

D	1	-1	2	-1	1	3	-1	-1	-2	1
D2	1	1	4	1	1	9	1	1	4	1

$$\sum D^2 = 24$$

معامل ارتباط الرتب (Rank Correlation Coefficient) هو :

$$r_1 = 1 - \frac{6\sum D^2}{n(n^2-1)} = 1 - \frac{6(24)}{10(10^2-1)} = 0.855$$

إن القيمة العالية لمعامل ارتباط الرتب (r_1) توضح أن هناك علاقة قوية أو قريبة بين الأداء في العمل الصفي والأداء في الإمتحان ، الطلبة مع أداء جيد خلال السنة في العمل الصفي سيكونون جيدين في إمتحاناتهم أيضاً والعكس بالعكس .

4-2 معاملات الارتباط الجزئي (Partial Correlation Coefficients) .

معامل الارتباط الجزئي يقيس العلاقة بين أي متغيرين عندما تكون بقية المتغيرات المرتبطة بهذين المتغيرين يحافظ عليها ثابتة (أي تكون ثابتة بدون تغيير) ، مثلاً لنفرض أننا نريد أن نقيس الارتباط بين عدد كؤوس المشروبات الحارة (X_1) المستهلكة في أحد المصايف وعدد السياح (X_2) الذين يزورون ذلك المصيف ، من الواضح أن كلا المتغيرين متأثران بقوة بحالة الجو والتي

من الممكن أن نرمز لها بـ (X_3) ، على أسس مسبقة نحن نتوقع أن (X_2, X_1) مرتبطان إيجابياً : عندما يصل عدد كبير من السياح الى المصيف يجب أن نتوقع إستهلاكاً عالياً من المشروبات الحارة والعكس بالعكس ، إن حساب معامل الارتباط البسيط بين (X_2, X_1) ربما لا يوضح لنا العلاقة الحقيقية التي تربط بين المتغيرين وذلك بسبب تأثير متغير ثالث وهو حالة الجو (X_3) ، بعبارة أخرى إن العلاقة الإيجابية أعلاه بين عدد السياح وعدد المشروبات الحارة المستهلكة من المتوقع أن تكون صحيحة إذا افترضنا إن حالات الجو أو المناخ ثابتة ، فإذا تغير المناخ ، فالعلاقة بين (X_2, X_1) ربما تتحرف الى مدى يبدو حتى علاقة سلبية ، وهكذا فإذا كان الجو حاراً ، فإن عدد السياح سيكون كبيراً ولكن بسبب الحرارة سوف يفضلون إستهلاك مشروبات باردة أكثر من المشروبات الحارة ، فإذا تجاهلنا حالة الجو ونظرنا فقط الى (X_1) ، فإننا سنلاحظ ارتباطاً سالباً بين هذين المتغيرين ، وهذه العلاقة موضحة بحقيقة أن المشروبات الحارة والى المدى نفسه عدد السياح أو الزوار متأثرة بالحرارة .

من أجل أن نقيس الارتباط الحقيقي بين المتغير (X_1) والمتغير (X_2) علينا أن نجد طريقاً يساعدنا في أن نأخذ في الحساب التغيرات الحاصلة في المتغير الثالث الذي هو (X_3) (حالات الجو) ، وهذا الطريق يمكن أن ينجز بوساطة إستخدام معامل الارتباط الجزئي بين (X_2, X_1) عندما يكون (X_3) ثابتاً ، إن معامل الارتباط الجزئي هذا يقرر بتعابير معاملات الارتباط البسيط بين مختلف المتغيرات الداخلة في علاقة متعددة .

في مثالنا الحالي هناك ثلاث معاملات ارتباط بسيط :

$$r_{12} = X_2, X_1 \text{ معامل الارتباط بين}$$

$$r_{13} = X_3, X_1 \text{ معامل الارتباط بين}$$

$$r_{23} = X_3, X_2 \text{ معامل الارتباط بين}$$

وهناك معاملا ارتباط جزئي :

معامل الارتباط الجزئي بين (X_2, X_1) عندما يكون (X_3) ثابتاً $r_{12.3} =$

$$r_{12.3} = \frac{r_{12} - (r_{13})(r_{23})}{\sqrt{(1 - r_{13}^2)(1 - r_{23}^2)}}$$

معامل الارتباط الجزئي بين (X_3, X_1) عندما يكون (X_2) ثابتاً $r_{13.2} =$

$$r_{13.2} = \frac{r_{13} - (r_{12})(r_{23})}{\sqrt{(1 - r_{12}^2)(1 - r_{23}^2)}}$$

وسنعود الى مناقشة هذا الجانب من معامل الارتباط الجزئي عند دراسة موضوع الإنحدار .

5-2 حدود نظرية الارتباط الخطي .

إن تحليل الارتباط له حدود أو محددات مهمة بوصفه أسلوب لدراسة العلاقات الإقتصادية (Economic Relationships) .
أولاً : إن القانون (r) يطبق فقط عندما تكون العلاقة بين المتغيرات خطية ، ولكن ربما يكون هناك متغيران مرتبطان بقوة في علاقة غير خطية ، يجب أن يكون واضحاً أن قيمة صفر لإرتباط متغيرين (Y, X) وكونهما إحصائياً مستقلان ليس شيئاً واحداً فالإرتباط يتضمن :

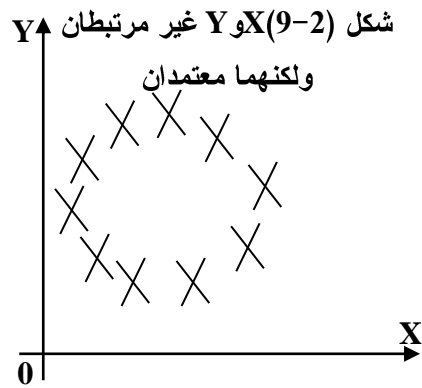
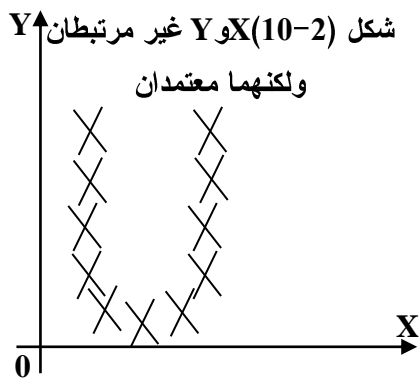
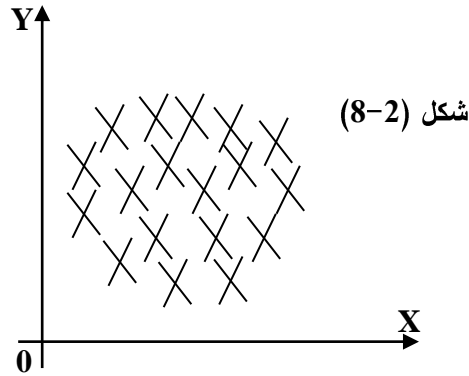
$$r = \frac{\sum x_i y_i}{\sqrt{\sum x^2} \sqrt{\sum y^2}} = 0$$

بينما الإستقلال الإحصائي للمتغيرين (Y, X) يتضمن احتمالية إن (Y_i, X_i) يحدثان آنياً ، أي في الوقت نفسه هي ناتج الإحتمال الفردي لكل متغير

$$P (X \text{ and } Y) = P (X) . P(Y)$$

من المتغيرات لها بالتأكد معامل تباين مشترك (Covariance) يساوي صفراً وهي بهذا غير مرتبطة ببعضها :

معامل الارتباط الخطي بين متغيرين مستقلين يساوي صفراً كما في الشكل (8-2) ، ولكن معامل الارتباط الخطي المساوي للصفر لا يتضمن بالضرورة الإستقلال (Independence) ، بكلمات أخرى فإن المتغيرات غير المرتبطة (Uncorrelated Variables) ربما تكون إحصائياً معتمدة (dependent) ، مثلاً اذا كان المتغير (X) والمتغير (Y) لهما مشاهدات أو نقاط تقع على دائرة أو على شكل حرف (U) باللغة الإنجليزية كما في الشكلين (9-2) و (10-2) ، فالعلاقة بينهما تامة أو كاملة ولكن غير خطية .



المتغيرات هنا إحصائياً معتمدة ، على الرغم من أن التباين المشترك (Covariance) ، ومعامل الارتباط الخطي هما صفرًا ، إن غياب الارتباط الخطي (Linear Correlation) لا يتضمن غياب الاعتماد بين المتغيرات .

ثانياً : إن المحدد أو المقيد الثاني لنظرية الارتباط هو أن معامل الارتباط مقياس لدرجة التباين المشترك للمتغيرات لا يتضمن بالضرورة أية علاقة دالية (A Functional Relationship) بين المتغيرات الموجودة في الارتباط ، إذ إن نظرية الارتباط (Correlation Theory) لا تبنى أو تؤسس أو تبرهن أية علاقة سببية (A causal Relationship)، بين المتغيرات .

إن نظرية الارتباط تسعى الى إكتشاف في ما إذا كان هناك تباين أو تغير مشترك موجود بين المتغيرات ، ولكنها لا توضح أن التغيرات أو الانحرافات مثلاً في المتغير (Y) هي بسبب تغيرات في أو انحرافات في المتغير (X) أو بالعكس . إن معرفة قيمة (r) لوحدها سوف لن تمكننا من التنبؤ بقيمة (Y) من (X) ، إن ارتباطاً عالياً بين المتغيران (Y,X) ربما يصف لنا أي واحد من المواقف التالية :

- 1- التغيرات في (X) هي سبب التغيرات أو الانحرافات في (Y).
- 2- التغيرات أو الانحرافات في (Y) هي سبب التغيرات أو الانحرافات في (X)
- 3- إن (X) و (Y) معتمدان معاً (Jointly dependent) أو هناك إتجاهين أو طريقين للسببية (Two-Way of Causation) وهذا يعني أن نقول أن (Y) هو سبب لـ (X) أو يتقرر بواسطة (X) ، وأيضاً (X) هي سبب لـ (Y) أو تقرر بواسطة (Y) ، مثلاً في أي سوق من الأسواق فإن $P = F(Q)$ أو $Q = F(P)$ ولذلك نقول هناك طريقين للسببية بين الكمية (Q) والسعر (P) بعبارة أخرى فإن (P,Q) يتقرران آنياً (Simultaneously) .

- 4- هناك عامل أو عنصر مشترك آخر (Z) الذي يؤثر على (Y,X) بطريقة توضح علاقة قريبة بينهما ، وهذا غالباً يحصل في السلاسل الزمنية عندما يكون هناك ارتباطاً عالياً بين (Y,X) حتى ولو كانوا مستقلين سببياً .
- 5- الارتباط بين (Y,X) ربما يكون بسبب الصدفة (due to chance).

وخلاصة القول أن نظرية الارتباط لا تبني علاقة دالية ، وهذا يعني أن نظرية الارتباط لا تعطينا أو لا تبين أي المتغيرات هو المتغير المعتمد (Dependent Variable) ، وأي المتغيرات هو المتغير التوضيحي (Explanatory Variable) . من خلال البحث الدقيق باستخدام نظرية الإقتصاد القياسي فقط نستطيع أن نصل الى نتيجة حول العلاقة السببية بين المتغيران (Y,X) ، وبعبارة أخرى هل أن (X) هو السبب لـ (Y) أم لا ، والأكثر من هذا أن تحليل الارتباط لا يعطينا قيمة رقمية لمعاملات العلاقة ، أي لا يعطي تقديرات للميل (Slope) والتقاطع الثابت (Constant Intercept) للدالة. إذاً يمكن أن نقول أن معامل الارتباط الخطي يقيس درجة محور وإستقطاب النقاط في شكل الإنتشار حول خط مستقيم ولكنه لايعطي معادلة ذلك الخط المستقيم ، وهذا يعني عدم إعطاء قيم رقمية للمعاملات (parameters) لتلك الدالة المعبر عنها بالخط المستقيم ، هذه المعلمات يمكن أن تكون أجزاء من المرونة أو الميل أو المضاعف ، طالما تعلق الأمر بالنظرية الإقتصادية ، ومعرفة القيم الرقمية لهذه المعلمات على نحو خاص مهمة جداً للمنظمين وصانعي السياسات الإقتصادية .

ومن أجل تقدير هذه المعلمات للعلاقة المعينة فإننا نطبق طرقاً مختلفة ، سوف نبدأ بدراسة طريقة المربعات الصغرى الإعتيادية للإنحدار ، وذلك لأن هذه الطريقة هي الأبسط من جميع الطرق ، والأكثر من كله أنها تشكل الأساس لمعظم الطرق الأخرى في أساليب الإقتصاد القياسي .

الفصل الثالث
طبيعة تحليل الإنحدار

طبيعة تحليل الانحدار

1-3 الأصل التاريخي لمصطلح الانحدار (Regression) .

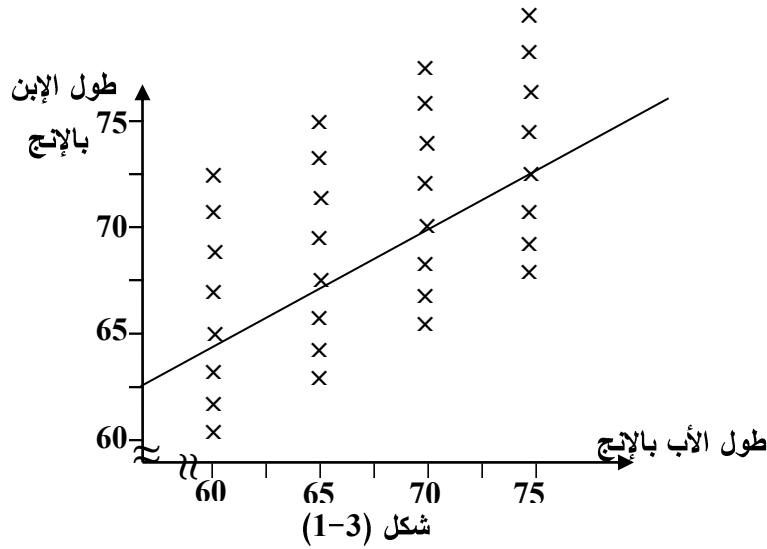
لقد أدخل مصطلح الانحدار من قبل فرانسيس كالتون (Francis Galton) في بحث مشهور وجد كالتون أنه على الرغم من أن الآباء والأمهات طوال القامة من المتوقع أن يكون أبنائهم طوالاً ، والآباء والأمهات قصار القامة من المتوقع أن يكون أبنائهم قصاراً ، فإن توزيع أطوال (heights) السكان لم يتغير على نحو كبير من جيل إلى آخر ، والتوضيح الذي عرضه كالتون كان أن هناك ميل لمعدل طول الأطفال مع آباء وأمهات بطول معين للحركة أو الانحدار نحو (regress) أو باتجاه معدل الطول للسكان كافة . إن قانون كالتون الكوني في الانحدار قد أثبتت صحته من قبل صديقه كارل بيرسون (Karl Pearson) ، الذي جمع أكثر من ألف رقم حول أطوال مجموعات من العوائل ، لقد وجد أن معدل أطوال أبناء مجموعة من الآباء طوال القامة كان أقل من طول آبائهم ، وإن معدل طول أبناء مجموعة من الآباء قصار القامة كان أطول من أطوال آبائهم ، وهكذا فإن إنحدار طول الأبناء طوال وقصار القامة على معدل طول كل الرجال .

2-3 التفسير الحديث للانحدار .

إن تحليل الانحدار يهتم بدراسة اعتماد متغير واحد والذي هو المتغير المعتمد (dependent variable) على متغير واحد أو أكثر . يسمى المتغير التوضيحي أو التفسيري (Explanatory Variable) مع رؤية أو نظرة لتقدير معدل قيمة المتغير المعتمد للمجتمع الإحصائي والتنبؤ به على أساس قيم المتغير الآخر أو التوضيحي المعروفة والموجودة في عينة إحصائية .

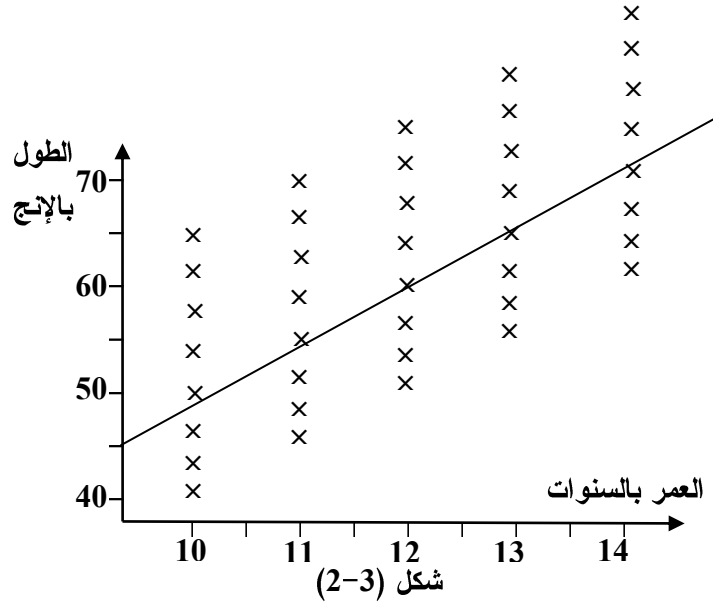
أمثلة :

1- إذا عدنا الى قانون كالتون في الانحدار الكوني ، نجد كالتون كان يرغب في إيجاد سبب وجود الإستقرارية (Stability) في توزيع أطوال السكان، ولكن في الرؤية الحديثة ليست مع هذه الصيغة في التوضيح ، ولكن مع إيجاد كيف أن معدل الطول للأبناء يتغير عندما يكون طول الأب معروفاً ، بعبارة أخرى نقول أن إهتمامنا بالتنبؤ بمعدل طول الأبناء عندما تكون أطوال الآباء معروفة ، ومن أجل أن نرى كيف يمكن عمل ذلك لناخذ الشكل البياني الآتي وهو عبارة عن شكل إنتشار (Scatter Diagram) .



يبين الشكل (1-3) توزيع أطوال الأبناء في مجتمع إحصائي (السكان) المقابلة لقيم معطاة لأطوال الآباء ، من الملاحظ ان القيم المقابلة لأي طول من أطوال الآباء هناك مدى (Range) أو توزيع (Distribution) لأطوال الأبناء ، ولكب يجب أن نلاحظ أن معدل طول الأبناء يزداد كلما يزداد طول الآباء ، ولنوضح ذلك رسمنا عبر نقاط الإنتشار خطأ مستقيماً وهو يبين كيف أن معدل أطوال الأبناء يزداد مع زيادة أطوال الآباء ، وهذا الخط المستقيم كما سوف

نرى يسمى خط الانحدار (The Regression Line)، لاحظ أن هذا الخط له ميل موجب ، ولكن الميل أقل من الواحد وهذا في تطابق مع إنحدار كالتون .
2- لنأخذ شكل الانتشار الآتي الذي يعطينا توزيع أطوال الأبناء أو الأولاد مقاسة عند أعمار ثابتة في مجتمع سكاني إفتراضي .



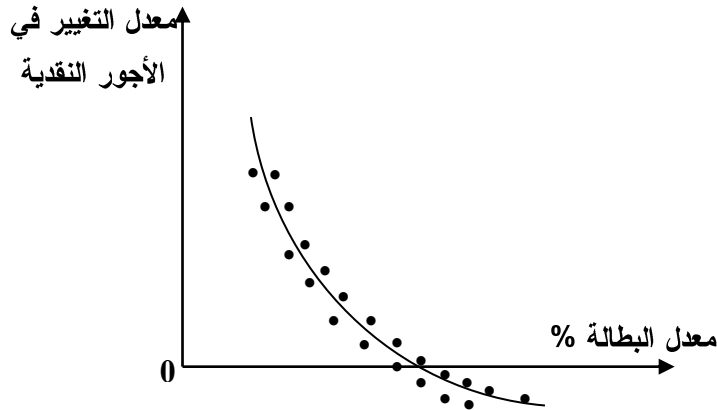
نلاحظ في الشكل (2-3) إن المقابل لأي عمر هناك مدى من الأطوال ، من الواضح أنه ليس كل الأولاد في عمر معين لهم أطوال متشابهة ، ولكن الطول على مستوى المعدل يزداد مع زيادة العمر (الى سن أو عمر معين طبعاً) وهكذا فإن معرفة العمر ربما يجعلنا قادرين على التنبؤ بمعدل الطول المقابل أو المرافق لذلك العمر .

3- ننتقل الآن الى الأمثلة الإقتصادية .

ربما يكون الإقتصادي راغباً في دراسة إعتداد المصروف الإستهلاكي الشخصي على الدخل تحت التصرف بعد فرض الضريبة (الدخل الشخصي الحقيقي) إن مثل هذا التحليل ربما يكون مفيداً في تقدير الميل الحدي للإستهلاك

(MPC) (Marginal Propensity to Consume)، وذلك هو معدل التغيير في الإنفاق الإستهلاكي المرافق للتغيير في الدخل الحقيقي بقيمة دينار واحد .
 إن محتكراً (A monopolist) يستطيع أن يثبت السعر أو الإنتاج (ولكن ليس كليهما) ، ربما يرغب في إيجاد إستجابة الطلب على منتج له للتغيير في السعر ، إن مثل هذه التجربة ربما تمكنه من تقدير المرونة السعرية (الإستجابة السعرية) من قبل الطلب على المنتج ، وربما تساعد في تقدير السعر الأكثر ربحية .

ربما يكون المختص بإقتصاد العمل يرغب أن يدرس معدل التغيير في الأجور النقدية (Money Wages) في علاقته بمعدل البطالة (Unemployment) إن البيانات التاريخية تبدو في الشكل (3-3) الآتي .



شكل (3-3)

إن المنحنى الذي يبدو في شكل الإنشار منحنى يدعى منحنى فيلبس الذي يربط التغيرات في الأجور النقدية الى معدل البطالة ، إن مثل هذا الشكل ربما يمكننا أو يمكن المختص بإقتصاد العمل من التنبؤ بمعدل التغيير في الأجور النقدية عند مستوى معين من معدل البطالة ، وإن هذه المعرفة ربما تساعد في قول شيء بخصوص العملية التضخمية في الإقتصاد الوطني ، وذلك لأن الزيادات في الأجور النقدية من المحتمل أن تعكس بزيادة في الأسعار .

3-3 الإعتدال الإحصائي مقابل الإعتدال الدالي .

من الأمثلة السابقة نلاحظ أننا في تحليل الانحدار نهتم بما يعرف بالإعتدال الإحصائي (Statistical Dependence) وليس الإعتدال الدالي (Functional Dependence) بين المتغيرات ، ففي العلاقات الإحصائية بين المتغيرات ، فإننا بشكل رئيس نتعامل مع متغيرات عشوائية (Random) أو متغيرات إحصائية (Stochastic Variables) وهي متغيرات لها توزيع إحصائي ، بينما في العلاقات التامة أو التقريرية أو الدالية ، فإننا نتعامل مع متغيرات ، ولكن هذه المتغيرات ليست متغيرات عشوائية أو متغيرات إحصائية .

إن إعتدال إنتاج المحصول على درجة حرارة الجو ومعدل سقوط الأمطار والأيام المشمسة والخصوبة مثلاً هو إعتدال إحصائي في طبيعته ، بمعنى أن المتغيرات التوضيحية على الرغم من أهميتها المؤكدة سوف لن تمكن المختص بالمحاصيل الحقلية من التنبؤ بإنتاج المحصول بدقة وذلك بسبب وجود أخطاء في قياس تلك المتغيرات فضلاً عن وجود متغيرات أخرى تؤثر جماعياً على إنتاج المحصول ، ولكن ربما من الصعوبة التعرف عليها على نحو فردي .

الفصل الرابع
تحليل الإنحدار البسيط

تحليل الإنحدار البسيط

1-4 مقدمة

نحاول في هذا الفصل مناقشة مفهوم الإنحدار بتفصيل أكثر ومن خلال هذه المناقشة ندخل الى عالم نظرية تحليل الإنحدار بأبسط صيغها وهي صيغة المتغيرين . والسبب في دراسة هذه الصيغة أولاً ليس بالضرورة لأنها عملية كافية ، ولكن لأنها تعرض الأفكار الأساسية لتحليل الإنحدار على نحو مبسط كلما كان ذلك ممكناً . وإن بعض هذه الأفكار يمكن أن توضح بإستخدام الأشكال البيانية ذات البعدين ، وتحليل الإنحدار المتعدد سيكون بأي شكل من الأشكال هو عبارة عن إمتداد منطقي للإنحدار البسيط .

يهتم تحليل الإنحدار على نحو كبير بتقدير أو التنبؤ بقيمة الوسط الحسابي أو معدل قيمة المتغير المعتمد على أساس قيم ثابتة ومعروفة للمتغير التوضيحي أو المتغيرات التوضيحية ، ومن أجل أن نفهم كيفية عمل تحليل الإنحدار لنأخذ المثال الآتي :

لنتصور بلداً افتراضياً يتكون من عدد سكان كلي يساوي (60) عائلة ، ونفترض أننا نرغب في دراسة العلاقة بين الإنفاق الإستهلاكي العائلي الأسبوعي (Y) والدخل تحت التصرف ، بعد فرض الضريبة الأسبوعي (X) ، وعلى نحو أكثر تحديداً نفترض أننا نريد أن نتنبأ بالوسط الحسابي لمستوى الإنفاق الإستهلاكي الأسبوعي العائلي عندما يكون دخل العائلة الواحدة معروفاً . ولتحقيق الهدف نفترض أننا نقسم هذه اعوائل الـ (60) الى (10) مجموعات يكون الدخل في كل مجموعة متشابهاً تقريباً بين العوائل وثم القيام بتفحص الإنفاق الإستهلاكي أو المصروفات الإستهلاكية عند كل مستوى من مستويات الدخل المذكورة لمجموعات العوائل .

جدول (1-4)

$Y \downarrow X \rightarrow$	80	100	120	140	160	180	200	220	240	260
المصروفات الإستهلاكية الأسبوعية	55	65	79	80	102	110	120	135	137	150
	60	70	84	93	107	115	136	137	145	152
	65	74	90	95	110	120	140	140	155	175
	70	80	94	103	116	130	144	144	165	178
	75	85	89	108	118	135	145	145	175	180
	88	113	125	140	189	185
	115	191
المجموع	325	462	445	707	678	750	685	1043	966	1211

إن البيانات الافتراضية في الجدول (1-4) لغرض المناقشة . إفترض
إن مستويات الدخل المعطاة في الجدول (1-4) فقط مشاهدة فعلاً ، إن الجدول
(1-4) يفسر كما يأتي :

عند مستوى دخل أسبوعي (80) دينار مثلاً هناك خمسة عوائل تكون
مصروفاتها الإستهلاكية الأسبوعية بمدى بين (55) دينار الى (75) دينار ،
وبالطريقة نفسها اذا كان مستوى الدخل $(X) = (240)$ دينار معطى أو معروف
هناك ستة عوائل تكون مصروفاتها الإستهلاكية الأسبوعية تقع بين (137) دينار
الى (189) دينار .

بكلمات أخرى كل عمود في الجدول (1-4) يعطينا توزيع الإنفاق
الإستهلاكي (Y) المرافق لمستوى ثابت من الدخل (X) ، بمعنى أنه يعطي
التوزيع المشروط (Conditional Distribution of Y) للمتغير (Y)
(المشروط على قيم معطاة من المتغير المستقل (X) الدخل) .

يجب أن نلاحظ إن البيانات في الجدول (4-1) تعبر عن المجتمع الإحصائي (population) ، تستطيع أن تحسب بسهولة الإحتمالات المشروطة (Conditional probabilities) للمتغير المعتمد (Y) وهي :

$$P(Y|X)$$

إحتمالية (probability) حصول (Y) عندما تكون (X) معروفة أو معطاة كما يأتي :

بالنسبة الى $X = 80$ مثلاً هناك خمسة قيم وهي :

55 60 65 70 75

ولذلك اذا أعطينا أن $X = 80$ فإن إحتمالية أن نحصل على أي من القيم الخمسة المعبرة عن المصروفات الإستهلاكية هي $\frac{1}{5}$ ، وبصيغة الرموز :

$$P(Y = 55 | X = 80) = \frac{1}{5}$$

وبالطريقة نفسها فإن :

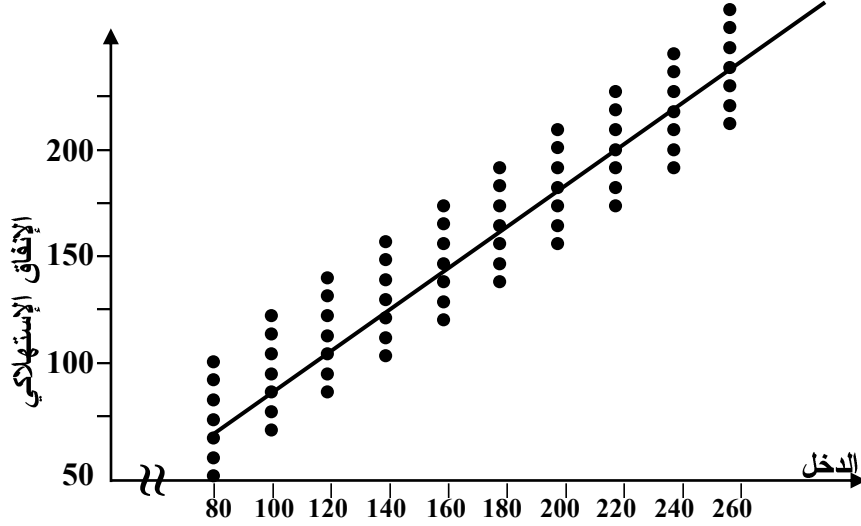
$$P(Y = 150 | X = 260) = \frac{1}{7}$$

وهكذا .

إن الإحتمالات المشروطة للبيانات في الجدول (4-1) معطاة في الجدول (4-2) الآتي :

$X \rightarrow$	80	100	120	140	160	180	200	220	240	260
$P(Y X_i)$										
الإحتمالات المشروطة $P(Y X_i)$	$\frac{1}{5}$	$\frac{1}{6}$	$\frac{1}{5}$	$\frac{1}{7}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{5}$	$\frac{1}{7}$	$\frac{1}{6}$	$\frac{1}{7}$
	$\frac{1}{5}$	$\frac{1}{6}$	$\frac{1}{5}$	$\frac{1}{7}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{5}$	$\frac{1}{7}$	$\frac{1}{6}$	$\frac{1}{7}$
	$\frac{1}{5}$	$\frac{1}{6}$	$\frac{1}{5}$	$\frac{1}{7}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{5}$	$\frac{1}{7}$	$\frac{1}{6}$	$\frac{1}{7}$
	$\frac{1}{5}$	$\frac{1}{6}$	$\frac{1}{5}$	$\frac{1}{7}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{5}$	$\frac{1}{7}$	$\frac{1}{6}$	$\frac{1}{7}$
	$\frac{1}{5}$	$\frac{1}{6}$	$\frac{1}{5}$	$\frac{1}{7}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{5}$	$\frac{1}{7}$	$\frac{1}{6}$	$\frac{1}{7}$
	$\frac{1}{6}$	$\frac{1}{7}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{7}$	$\frac{1}{7}$
	$\frac{1}{7}$	$\frac{1}{7}$	$\frac{1}{7}$

المتوسطات الحسابية لـ (Y) المشروطة	65	77	89	101	113	125	137	149	161	173



شكل (1-4) يبين التوزيع المشروط للإتفاق من مستويات دخل مختلفة

الآن بالنسبة لكل توزيع إحصائي مشروط لـ (Y) نستطيع أن نحسب الوسط الحسابي أو قيمة المعدل تعرف بالوسط الحسابي المشروط أو التوقع المشروط يشار إليه كما يأتي :

$$E(Y|X)$$

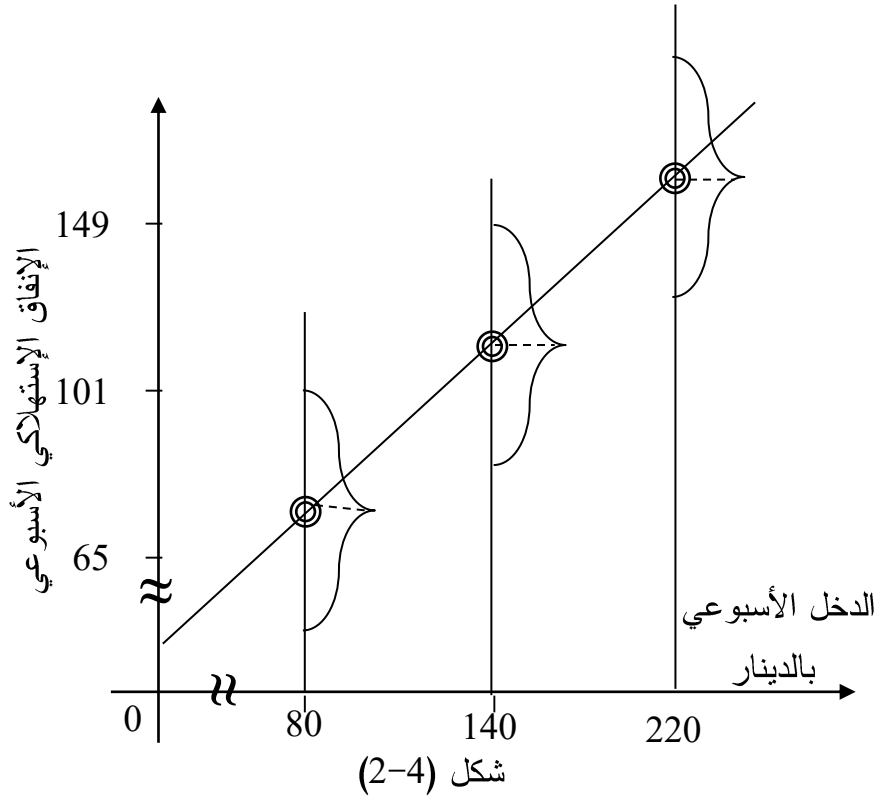
ويقرأ كما يأتي : القيمة المتوقعة لـ (Y) عند مستوى معطى أو معروف من (X) ، (يجب أن نلاحظ أن القيمة المتوقعة ببساطة هي الوسط الحسابي للمجتمع الإحصائي) وبالنسبة للبيانات الافتراضية المذكورة في المثال يمكن أن نحسب هذه التوقعات المشروطة بسهولة من خلال ضرب قيم (Y) المعطاة في الجدول (1-4) في نسب احتمالاتها المشروطة المعطاة في الجدول (2-4) وجمع النواتج .

وللتوضيح فإن الوسط الحسابي المشروط أو توقع (Y) ، عندما تكون

قيمة $X = 80$ هو :

$$55\left(\frac{1}{5}\right) + 60\left(\frac{1}{5}\right) + 65\left(\frac{1}{5}\right) + 70\left(\frac{1}{5}\right) + 75\left(\frac{1}{5}\right) = 65$$

وهكذا فإن بقية قيم الوسط الحسابي المشروط لـ (Y) أو توقع (Y) موجود في الجدول (3-2) وقبل الإستمرار في توضيح الموضوع من المفيد أن نرى بيانات الجدول (4-1) بصيغة شكل الإنتشار مبين في الشكل (4-1) ، إن شكل الإنتشار يبين التوزيع المشروط لـ (Y) المرافقة لقيم مختلفة من (X) ، على الرغم من وجود إنحرافات (Variations) في المصروفات الإستهلاكية للعائلة فإن الشكل (4-1) يبين بوضوح أن الإنفاق الإستهلاكي على مستوى المعدل (on average) يزداد كلما يزداد الدخل ، بعبارة أخرى نقول أن شكل الإنتشار يوضح أن قيم الوسط الحسابي المشروط لـ (Y) تزداد كلما يزداد (X) وهذا يمكن أن يبدو أكثر وضوحاً إذا ركزنا على النقاط كبيرة الحجم التي تعبر عن أوساط حسابية مشروطة مختلفة لـ (Y) ، إن شكل الإنتشار يبين هذه المتوسطات الحسابية المشروطة تقع تماماً على خط مستقيم مع ميل موجب ، وهذا الخط المستقيم يعرف أنه خط إنحدار ، وبدقة أكثر إنه منحنى إنحدار (Y) على (X) ، وهندسياً نقول أن منحنى إنحدار معين ببساطة هو عبارة عن موقع (locus) المتوسطات المشروطة أو موقع توقعات قيم المتغير المعتمد لقيم ثابتة للمتغير التوضيحي أو التفسيري ، وهذه يمكن رسمها في الشكل (4-2) الذي يبين أنه لكل (X) هناك قيم للمجتمع الإحصائي لـ (Y) (افترض أنها توزع توزيعاً طبيعياً) ومعها المتوسط أو الوسط الحسابي المشروط ، إن خط الإنحدار أو منحنى الإنحدار يمر عبر نقاط المتوسطات الحسابية المشروطة .



2-4 مفهوم دالة إنحدار المجتمع الإحصائي .

ومن المناقشة السابقة وبخاصة للشكلين (1-4)(2-4) يبدو واضحاً أن كل متوسط أو وسط حسابي مشروط $E(Y|X_i)$ دالة في (X_i) وبصيغة الرمز :

$$E(Y|X_i) = f(X_i) \dots \dots \dots (1-2-4)$$

عندما تشير $f(x_i)$ الى دالة المتغير التوضيحي أو التفسيري (X_i) في مثالنا الافتراضي $E(Y|X_i)$ دالة خطية في (X_i) .

إن المعادلة (1-2-4) تعرف بوصفها دالة إنحدار مجتمع إحصائي بمتغيرين (PRF)(population Regression Function) ، أو إنحدار

المجتمع الإحصائي للإختصار ، وهذه العلاقة الدالية تنص على أن الوسط أو المتوسط الحسابي للمجتمع الإحصائي لتوزيع (Y) عندما تكون (X_i) معطاة هو دالياً مرتبط بـ (X) بعبارة أخرى أنها تخبرنا كيف أن قيمة المعدل للمجتمع الإحصائي لـ (Y) تتغير (Varies) مع قيم (X) .

ما هو الشكل الذي تأخذه الدالة (f (X_i) ؟

إن هذا السؤال مهم ، وذلك لأنه في المواقف الحقيقية نحن لا نعرف أو ليس لدينا كامل أو كل المجتمع الإحصائي جاهزاً للإختبار والتفحص ، إن الشكل الدالي لدالة إنحدار المجتمع الإحصائي (PRF) هو لذلك مسألة تجريبية على الرغم من أنه في بعض الحالات ، ربما تخبرنا النظرية ببعض المعلومات في هذا الصدد ، مثلاً إن إقتصادياً ربما يضع الإنفاق الإستهلاكي بوصفه مرتبط خطياً بالدخل .

لذلك وكتقريب أولي أو كفرضية عملية ربما نفترض أن دالة إنحدار المجتمع الإحصائي (PRF) هي دالة خطية لـ (X_i) ولنقل من نوع :

$$E(Y|X_i) = b_0 + b_1 X_i \dots\dots\dots (2-2-4)$$

عندما تكون :

(b₀, b₁) معاملات مجهولة ولكنها معاملات ثابتة (Fixed parameters) تعرف بأنها معاملات الإنحدار ؛ كما أن (b₀) تعرف أنها معلمة التقاطع ، وإن (b₁) تعرف أنها معامل أو معلمة الإنحدار ، إن المعادلة (2-2-4) ذاتها تعرف أنها دالة إنحدار المجتمع الإحصائي الخطية ، أو ببساطة إنحدار المجتمع الإحصائي الخطي .

3-4 التحديد الإحصائي لدالة إنحدار المجتمع الإحصائي .

واضح من الشكل (1-4) انه كلما يزداد دخل العائلة فإن الإنفاق الإستهلاكي للعائلة على مستوى المعدل يزداد أيضاً ، ولكن ماذا حول الإنفاق الإستهلاكي لعائلة منفردة في علاقته بمستوى دخلها الثابت ؟

واضح من الجدول (1-4) والشكل (1-4) إن الإنفاق الإستهلاكي لعائلة منفردة ليس بالضرورة يزداد كلما يزداد مستوى الدخل ، مثلاً من الجدول (1-4) نلاحظ أن ما يقابل مستوى الدخل (100) دينار هناك عائلة واحدة إنفاقها الإستهلاكي (65) دينار أقل من الإنفاق الإستهلاكي لعائلتين دخلهما الأسبوعي هو (80) دينار فقط ، ولكن لاحظ أن معدل الإنفاق الإستهلاكي للعوائل مع دخل أسبوعي (100) دينار هو أكبر من معدل الإنفاق الإستهلاكي للعوائل مع دخل أسبوعي (80) دينار (65 مقابل 77) .

عندئذ ماذا يمكن أن نقول حول العلاقة بين الإنفاق الإستهلاكي العائلي (للعائلة الواحدة) المرافق لمستوى معطى من الدخل ؟ .

نشاهد من الشكل (1-4) إنه اذا اعطينا مستوى الدخل (X_i) فإن الإنفاق الإستهلاكي العائلي الفردي سوف يستقطب حول معدل الإنفاق الإستهلاكي لكل العوائل عند ذلك المستوى من الدخل (X_i) بمعنى حول التوقع المشروط ، ولذلك نستطيع أن نعبر عن إنحراف الإنفاق الإستهلاكي العائلي (Y_i) حول القيمة المتوقعة له كما يأتي :

$$U_i = Y_i - E(Y|X_i)$$

أو

$$Y_i = E(Y|X_i) + U_i \dots\dots\dots (1-3-4)$$

عندما يكون الإنحراف (U_i) متغير عشوائي غير ممكن مشاهدته يأخذ قيمة موجبة أو قيمة سالبة ، وفنياً فإن (U_i) يعرف بوصفه الإضطراب الإحصائي (Stochastic Disturbance) أو حد الخطأ (Error Term) .

تبين لنا المعادلة (1-3-4) إن إنفاق العائلة المفردة (عندما يكون مستوى دخلها معروف) يساوي معدل الإنفاق الإستهلاكي لكل العوائل عند ذلك المستوى من الدخل زائداً بعض الكميات الموجبة أو السالبة والتي هي عشوائية، نفترض للحظات ان المتغيرات المحذوفة أو المهملة والتي تؤثر على المتغير المعتمد (Y) ، ولكنها غير موجودة في نموذج الإنحدار .

فإذا افترضنا أن $E(Y|X_i)$ هو خطي في (X_i) كما في المعادلة

(2-3-4) ربما نستطيع أن نكتب المعادلة (1-3-4) كما يأتي :

$$\begin{aligned} Y_i &= E(Y|X_i) + U_i \dots\dots\dots(2-3-4) \\ &= b_0 + b_1 X_i + U_i \end{aligned}$$

تؤشر أو تشير المعادلة (2-4-4) الى أن الإنفاق الإستهلاكي المشروط للعائلة الواحدة يرتبط خطياً بالدخل زائداً حد الإضطراب ، وهكذا فإن الإستهلاك للعوائل التي دخلها $X = 80$ دينار في الجدول (1-4) يمكن أن تعرض كما يأتي :

$$\left. \begin{aligned} Y_1 &= 55 = b_0 + b_1(80) + U_1 \\ Y_2 &= 60 = b_0 + b_1(80) + U_2 \\ Y_3 &= 65 = b_0 + b_1(80) + U_3 \\ Y_4 &= 70 = b_0 + b_1(80) + U_4 \\ Y_5 &= 75 = b_0 + b_1(80) + U_5 \end{aligned} \right\} \dots\dots\dots(3-3-4)$$

والآن اذا أخذنا القيمة المتوقعة ل(1-3-4) على الجانبين فنحصل على ما يلي :

$$\begin{aligned} E(Y|X_i) &= E[E(Y|X_i)] + E(U|X_i) \dots\dots\dots(4-3-4) \\ &= E(Y|X_i) + E(U|X_i) \end{aligned}$$

عندما إستخدمنا حقيقة إن القيمة المتوقعة للثابت هي القيمة الثابتة نفسها يجب أن نلاحظ بإعتناء أننا في المعادلة (4-3-4) قد إخذنا الموقع المشروط مشروطاً على مستوى معطى من (X_s) .

إن المعادلة (4-3-4) تتضمن أن :

$$E(U|X_i) = 0 \dots\dots\dots(4-3-5)$$

وهكذا فإن الافتراض أن خط الانحدار يمر عبر المتوسطات الحسابية المشروطة للمتغير المعتمد (Y) كما في الشكل (4-2) ، والذي يتضمن أن قيم المتوسطات الحسابية المشروطة للمتغير العشوائي (U_i) [مشروطة على قيمة معطاة لـ X] تساوي صفراً أو هي صفراً .
ومن المناقشة السابقة يتضح أن (4-2-2) و (4-3-2) هي أشكال متساوية إذا كانت :

$$E(U|X_i) = 0$$

ولكن التحديد الإجمالي (4-3-2) له فائدة في أنه يبين بوضوح أن هناك الى جانب الدخل متغيرات أخرى تؤثر في الإستهلاك (الإنفاق الإستهلاكي) ، وإن الإنفاق الإستهلاكي للعائلة المفردة لا يمكن أن يوضح على نحو تام وكامل من خلال المتغير أو المتغيرات الموجودة في الدالة (نموذج الانحدار) .

4-4 دالة إنحدار العينة .

عندما اقتصر حديثنا لحد الآن على قيم المجتمع الإحصائي (population) للمتغير المعتمد (Y) المناظرة أو المرافقة الى قيم ثابتة للمتغير المستقل أو التوضيحي (X) فإننا متعمدين أن نتجنب عملية أخذ العينات (يجب أن نلاحظ ان البيانات في الجدول (4-1) تعبر عن بيانات مجتمع إحصائي وليس بيانات عينة إحصائية) ولكن الآن أصبح الوقت مهياً لمواجهة مشكلات أخذ العينات ، وذلك لأن معظم المواقع العملية لا نملك فيها إلا قيم للمتغير المعتمد في عينة إحصائية يناظرها قيم ثابتة للمتغير المستقل أو التوضيحي أو

التفسيرى (X) ، وهذا يعني أن واجبنا الآن هو تقدير دالة إنحدار المجتمع الإحصائي على أساس معلومات من عينة إحصائية .
وللتوضيح لنفترض أن المجتمع الإحصائي في الجدول (4-1) كان غير معلوماً وإن المعلومات الوحيدة المتوافرة لنا كانت قد أختيرت عشوائياً ضمن عينة إحصائية (Sample) لقيم المتغير المعتمد (Y) تناظرها قيم ثابتة للمتغير المستقل (X) كما هي معطاة في الجدول (4-3) الآتي :

جدول (4-3)

Y	X
70	80
65	100
90	120
95	140
110	160
115	180
120	200
140	220
155	240
150	260

ليس كما هو الوضع في الجدول (4-1) نحن الآن لدينا قيمة واحدة للمتغير المعتمد (Y) مقابلة لكل قيمة من المتغير المستقل (X) ، أي مقابل كل (X) هناك قيمة واحدة (Y) .
إن الجدول (4-3) قد أختير عشوائياً من بيانات عن (Y) مناظرة نفسها من قيم المتغير المستقل أو التوضيحي (X) من المجتمع الإحصائي الموجود في الجدول (4-1) .

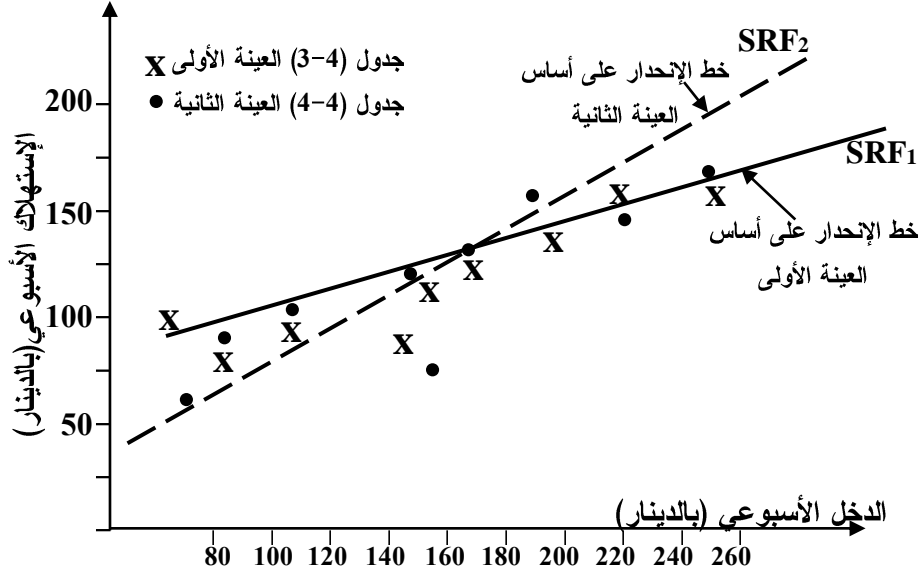
والسؤال الآن هو : من العينة الإحصائية المعبر عنها بالجدول (3-4) هل نستطيع أن نتنبأ بمعدل الإنفاق الإستهلاكي الأسبوعي (Y) في المجتمع الإحصائي بكامله المناظرة الى قيم (X) المختارة ؟ بعبارة أخرى هل نستطيع أن نقدر دالة إنحدار المجتمع الإحصائي (PRF) من بيانات العينة الإحصائية ؟ والجواب يمكن أن يتضمن بعض الشك في أننا ربما لا نكون قادرين على تقدير (PRF) على نحو دقيق ، وذلك بسبب التقلبات في أخذ العينات . ومن أجل أن نرى هذا سحبنا عينة إحصائية أخرى من المجتمع الإحصائي في الجدول (1-4) ، وكما هي معروضة في الجدول (4-4) الآتي :

جدول (4-4) عينة إحصائية عشوائية مأخوذة من بيانات جدول (1-4)

Y	X
55	80
88	100
90	120
80	140
118	160
120	180
145	200
135	220
145	240
175	260

فإذا رسمنا بيانات الجدولين (3-4)(4-4) في الشكل البياني (3-4)

الآتي :



الشكل (4-4) خط الإنحدار على أساس عينتين مختلفتين

في شكل الانتشار هناك خطي إنحدار لعينتين قد رسما فعلاً من أجل أن يوفقا منطقياً : إن دالة إنحدار العينة الأولى (SRF_1) تعتمد على العينة الأولى ودالة الإنحدار الثانية (SRF_2) تعتمد على العينة الثانية ، والسؤال هو أي من خطي الإنحدار يعبر عن خط إنحدار المجتمع الإحصائي الحقيقي ؟ .

ليس هناك طريقاً يجعلنا قادرين على نحو مطلق على تأكيد أي من الخطين المعروضين في الشكل (4-4) يعبر عن خط الإنحدار الحقيقي للمجتمع الإحصائي ، إن خطي الإنحدار في الشكل (4-4) يعرفان بوصفهما خطي إنحدار للعينات ولكنهما يمثلان في أفضل الأحوال تقريب للإنحدار الحقيقي للمجتمع الإحصائي .

إن العينة الإحصائية المقابلة للمعاملة (2-2-4) ربما تكتب كما يأتي :

$$\hat{Y}_i = \hat{b}_0 + \hat{b}_1 X_i \dots\dots\dots (1-4-4)$$

عندما يكون :

$$\hat{1} = \text{تقرأ هات أو كاب}$$

$$\hat{Y}_i = \text{مقدر لـ } E(Y|X_i)$$

$$b_0 = \hat{b}_0 \text{ مقدر}$$

$$b_1 = \hat{b}_1 \text{ مقدر}$$

والآن يمكننا أن نكتب المعادلة (1-4-4) بالصيغة الاحتمالية الآتية :

$$\hat{Y}_i = \hat{b}_0 + \hat{b}_1 X_i + \ell_i \dots \dots \dots (1-4-4)$$

عندما يكون :

ℓ_i = يمثل حد الإضطراب أو حد البواقي (Residual Term) وفكرياً أن هذا مشابه الى (U_i) ويمكن أن يعد بوصفه تقديراً لـ (U_i) إن (ℓ_i) قد أدخل الى دالة إنحدار المجتمع الإحصائي .

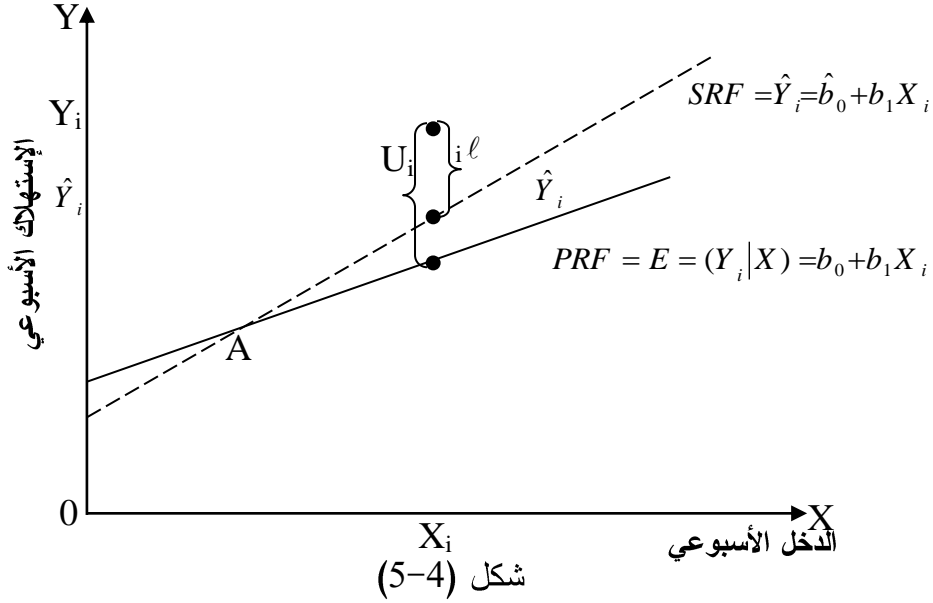
والان لنجمع كل الذي تعلمناه ونقول أن هدفنا الأولي في تحليل الإنحدار

هو لتقدير دالة أنحدار المجتمع الإحصائي (PRF) :

$$Y_i = b_0 + b_1 X_i + U_i \dots \dots \dots (2-3-4)$$

على أساس دالة إنحدار العينة الإحصائية () :

$$\hat{Y}_i = \hat{b}_0 + \hat{b}_1 X_i + \ell_i \dots \dots \dots (2-4-4)$$



لكل $X_i = X$ لدينا عينة إحصائية واحدة من المشاهدات وبصيغ
دالة $Y_i = Y$ إنحدار العينة (SRF) فإن القيم المشاهدة (Y_i) يمكن أن يعبر عنها
كما يأتي :

$$Y_i = \hat{Y}_i + \ell_i \dots \dots \dots (3-4-4)$$

وبصيغة دالة إنحدار المجتمع الإحصائي (PRF) يمكن أن يعبر عنها
كما يأتي :

$$Y_i = E(Y | X_i) + U_i \dots \dots \dots (4-4-4)$$

والآن يتضح من الشكل (5-4) السابق فإن (\hat{Y}_i) أعطت تقديراً عالياً
لقيم المتغير المعتمد الحقيقية $E(Y | X_i)$ المناظرة الى قيم معطاة للمتغير
المستقل أو التوضيحي (X_i) ، وبالطريقة نفسها فإن أية قيمة لـ (X_i) الى
اليسار من نقطة (A) فإن دالة إنحدار العينة سوف تعطي تقديراً منخفضاً لدالة
إنحدار المجتمع الإحصائي (PRF) .

إن هذه التقديرات العالية والمنخفضة هي حتمية (Inevitable) بسبب التقلبات (Fluctuations) في العينات الإحصائية .

والسؤال الحاسم الآن هو : إذا قبلنا أن دالة إنحدار العينة الإحصائية (SRF) تقرب لدالة إنحدار المجتمع الإحصائي (PRF) هل يمكننا أن نبتدع قاعدة أو طريقة (Method) معينة سوف تجعل هذا التقريب أقرب ما يكون إلى المجتمع الإحصائي كلما كان ذلك ممكناً ؟ .

بعبارة أخرى كيف يجب أن تبنى دالة إنحدار العينة الإحصائية ، بحيث تكون \hat{b}_0 قريبة قدر الإمكان من المعلمة الحقيقية (b_0) وكذلك تكون (\hat{b}_1) قريبة قدر الإمكان من المعلمة الحقيقية (b_1) . إن الإجابة على هذا السؤال ستكون في الفصول القادمة .

الفصل الخامس
نموذج الإنحدار الخطي البسيط
وطريقة المربعات الصغرى الإعتيادية

نموذج الانحدار الخطي البسيط وطريقة المربعات الصغرى الإعتيادية 5-1 مقدمة .

ثمة طرق إقتصادية قياسية عدة يمكن بواسطتها أن نحصل على تقديرات لمعلومات العلاقات الإقتصادية من المشاهدات الإحصائية ، نحاول في هذا الفصل دراسة طريقة المربعات الصغرى الإعتيادية (Ordinary Least Squares) .

إن الأسباب وراء التركيز على هذه الطريقة هي :
أولاً : إن المعلومات التي تقدر بها هذه الطريقة تكون قيم تقديراتها أكثر دقة .

ثانياً : طريقة الحساب في هذه الطريقة (OLS) على نحو عام بسيطة عند مقارنتها مع بقية الطرق الإقتصادية القياسية ، كما أنها لا تتطلب كثيراً من البيانات .

ثالثاً : إن طريقة المربعات الصغرى الإعتيادية (OLS) كانت قد أستخدمت في مدى واسع من العلاقات الإقتصادية مع نتائج مرضية ، وعلى الرغم من التحسن في أجهزة الحاسبات الإلكترونية والمعلومات الإحصائية التي تسهل استخدام طرق قياسية أكثر تعقيداً ، نجد أن الـ (OLS) لا زالت واحدة من الطرق الأكثر شيوعاً في الإستعمال في تقدير العلاقات في النماذج الإقتصادية القياسية .

رابعاً : إن هذه الطريقة (OLS) هي واحدة من العناصر الأساسية في معظم أساليب الإقتصاد القياسي .

سنبدأ هذا الفصل بنموذج الانحدار الخطي البسيط الذي يعبر عن علاقة بين متغيرين أحدهما المتغير المعتمد والآخر المتغير التوضيحي ومرتبطين بدالة خطية .

5-2 نموذج الإنحدار الخطي البسيط .

سنوضح معنى طريقة المربعات الصغرى بمثال نظرية العرض .
 إن نظرية العرض بأبسط أشكالها تفترض وجود علاقة إيجابية بين الكمية المعروضة من السلعة وسعرها مع بقاء الظروف والأشياء الأخرى ثابتة عندما يزداد السعر فإن الكمية المعروضة من السلعة ستزداد والعكس بالعكس .
 باتباع الأسلوب الإقتصادي القياسي فإن واجبنا الأول تحديد نموذج العرض وهذا يتضمن تحديد أي المتغيرات هو المتغير المعتمد ، وأي المتغيرات هو المتغير التوضيحي ، وكذلك تحديد عدد المعادلات الداخلة في النموذج والشكل الرياضي الدقيق ، وأخيراً نحدد التوقعات المسبقة التي تتعلق بإشارة وحجم المعلمات ، تزودنا النظرية الإقتصادية بالمعلومات الآتية المتعلقة بدالة العرض :

1- المتغير المعتمد هو الكميات المعروضة والمتغير التوضيحي هو السعر .

$$Y = F(X)$$

عندما يكون :

$$Y = \text{الكمية المعروضة من السلعة} .$$

$$X = \text{سعر السلعة} .$$

2- إن النظرية الإقتصادية لا تحدد كون العرض يجب أن يدرس بنموذج المعادلة الواحدة (Siple – equation Model) ، أو بنموذج أكثر تعقيداً مكوناً من نظام من المعادلات الآتية ، ونحن هنا اخترنا أن نبدأ مع نموذج المعادلة الواحدة ، وفي مراحل متقدمة سنقوم بدراسة النماذج الأكثر تعقيداً أو النماذج الواسعة .

3- إن النظرية الإقتصادية غير واضحة حول الشكل الرياضي للنموذج (خطي أو غير خطي) لدالة العرض ، ففي علم الإقتصاد نجد أن في الكتب في

بعض الأحيان يعبر عن العرض بخط مستقيم مع ميل موجب أو منحنى مع ميل موجب ، إن الأخير يتضمن علاقة غير خطية بين الكمية والسعر ، مرة أخرى نقول أن المختص بالإقتصاد القياسي يجب أن يقوم بتقرير شكل دالة العرض ، نبدأ بإفتراض أن المتغيرات مرتبطة بأبسط شكل رياضي ممكن وهو أن العلاقة بين الكمية والسعر علاقة خطية تأخذ الشكل الآتي :

$$Y_i = b_0 + b_1 X_i \dots\dots\dots(1-2-5)$$

إن هذا الشكل الرياضي يتضمن طريقاً واحداً للسببية بين المتغير (Y) والمتغير (X) : السعر هو سبب التغيرات في الكمية المعروضة وليس الطريق الآخر ، إن معلمات دالة العرض هي (b_1, b_0) وهدفنا هو أن نحصل على تقديرات بقيم رقمية لهما (\hat{b}_1, \hat{b}_0) بالنسبة لإشارة وحجم (\hat{b}_0) نلاحظ أنها إما أن تساوي صفراً (وهذا يعني أن الكمية من السلعة المعروضة تكون صفراً عندما يكون السعر صفراً) ، أو موجباً (وهذا يعني أن كمية من السلعة تعرض حتى عندما ينخفض السعر الى الصفر) ، عادةً فإن (\hat{b}_0) يجب ألا تكون بإشارة سالبة في دالة العرض .

بالنسبة لقيمة (\hat{b}_1) نلاحظ أنه في حالة معينة لدالة العرض نتوقع إن إشارة (\hat{b}_1) موجبة $(\hat{b}_1 > 0)$ ، وذلك لأن منحنى العرض بإرتفاع الميل الى الأعلى .

من المهم أن نختبر العلاقة بين المرونة السعرية للعرض والمعلومات

$(\hat{b}_0)(\hat{b}_1)$ نعود الى تعريف المرونة بالتعبير الاتي :

$$\begin{aligned} Np &= \frac{dQ}{dP} \cdot \frac{P}{Q} \\ &= \frac{dY}{dX} \cdot \frac{X}{Y} \end{aligned}$$

من دالة العرض نجد أن : $\frac{dY}{dX} = b_1$

في حساب المرونة من خط الانحدار نستخدم (\hat{b}_1) وقيم الوسط الحسابي للسعر (\bar{X}) والوسط الحسابي للكمية (\bar{Y}) في العينة .

$$\hat{N}_p = \hat{b}_1 \cdot \frac{\bar{X}}{\bar{Y}} \quad \text{وهكذا :}$$

ولكن وكما سنرى لاحقاً : $\bar{Y} = \hat{b}_0 + \hat{b}_1 \bar{X}$

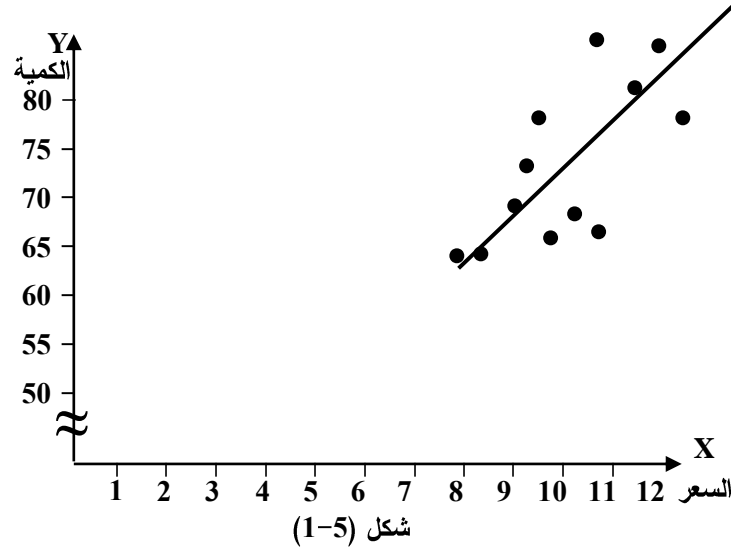
وهكذا عند التعويض عن (\bar{Y}) في معادلة المرونة نحصل على :

$$\hat{N}_p = \frac{\hat{b}_1 \bar{X}}{\hat{b}_1 \bar{X} + \hat{b}_0}$$

4- إن شكل دالة العرض المكتوب أعلاه يتضمن أن العلاقة بين الكمية والسعر هي علاقة تامة (Exact Relationship) ، وهذا يعني أن كل الانحرافات في (Y) يعود سببها الى التغير في (X) فقط وليس هناك عوامل أخرى تؤثر في المتغير المعتمد ، فإذا كان هذا هو الحقيقية فإن نقاط السعر والكمية اذا وضعناها في رسم بياني ستقع على خط مستقيم ، فإذا قمنا بجمع بيانات عن المشاهدات حول الكمية المعروضة فعلاً في السوق بأسعار مختلفة ، ونقوم برسم نقاط المشاهدات في شكل بياني فإننا سنلاحظ أن هذه النقاط لا تقع على خط مستقيم .

نفترض أننا لدينا عشرة نقاط عن المشاهدات حول (X) و (Y) معروضة في الجدول (1-5) الآتي :

عدد المشاهدات	(P) الكمية	(X) السعر
1	69	9
2	76	12
3	52	6
4	56	10
5	57	9
6	77	10
7	58	7
8	55	8
9	67	12
10	53	6
11	72	11
12	64	8



شكل الإنتشار لهذه المشاهدات يبين أن العلاقة بين السعر والكمية المعروضة لها شكل خط مستقيم تقريباً كما في الشكل (1-5) ، إن إنحرافات المشاهدات أو النقاط عن الخط شبه المستقيم ربما يعود الى عدة عناصر :

1- حذف متغيرات من الدالة .

في الواقع الإقتصادي الفعلي فإن كل متغير يتأثر بعدد كبير من العناصر والعوامل ، مثلاً نموذج الإستهلاك للعائلة يتقرر بدخل العائلة والأسعار وتركيب العمر والجنس لأفراد العائلة ومستوى دخل العائلة في الماضي والأذواق والديانة والحالة التعليمية والثروة الخ من العوامل . ولكن لا يمكن إدخال كل المتغيرات والعناصر المؤثرة على المتغير المعتمد في الدالة وذلك لأسباب مختلفة :

أ- إن بعض العناصر ربما تكون غير معروفة حتى بالنسبة للشخص الذي هو أكثر إطلاعاً على العلاقة أو الظاهرة تحت الدراسة . إن هذا التأخر في المعرفة هو الى مدى كبير يعود الى نظرية غير مكتملة حول إنحرافات المتغيرات الإقتصادية على نحو عام .

ب- حتى عندما نعرف أن بعض المتغيرات ملائمة لإدخالها في الدالة ، ولكن نواجه بمسألة كون بعض هذه العناصر غير قابلة للقياس إحصائياً ، هذه المتغيرات على نحو رئيس هي عناصر نفسية ، وعموماً هي عناصر أو عوامل نوعية (Qualitative Factors) مثل الأذواق والتوقعات والديانة وغيرها والتي يمكن التعبير عنها على نحو مرضي بالمتغيرات الصماء (Dummy Variables) .

ج- بعض العوامل أو العناصر هي عشوائية أو احتمالية تبدو بطريق غير قابل للتنبؤ ، وكذلك من حيث الزمن غير قابلة للتنبؤ ، ولذلك فإن تأثيرها يمكن أن نأخذها في الحساب على نحو مرضي ، مثلاً العدوى بالأمراض أو الهزة الأرضية وغيرها .

د- حتى ولو كانت كل العوامل أو العناصر المؤثرة معروفة ، فإن ما متوفر من بيانات إحصائية غالباً ما يكون غير كافٍ لقياس كل العناصر المؤثرة على العلاقة أو الظاهرة ، وهذا هو الحال على نحو خاص عندما نستعمل السلاسل الزمنية والتي عادةً تكون قصيرة ، وهكذا فإنه في معظم الحالات فإن المتغيرات الثلاثة أو الأربعة المهمة تدخل على نحو واضح في الدالة .

2- السلوك العشوائي أو الإحتمالي للبشر .

إن تبعثر النقاط للملاحظات حول خط الإنحدار المستقيم ربما يعود الى عنصر الخطأ الموروث في السلوك البشري إن ردود الفعل للإنسان هي الى مدى معين غير قابلة للتنبؤ (Unpredictable) وربما تسبب إنحرافات (Deviations) عن نموذج السلوك "الإعتيادي" الممثل بالخط المستقيم ، مثلاً في لحظة نزوة ربما يغير المستهلك نموذج أو خط إستهلاكه على الرغم من عدم تغيير الدخل أو الأسعار .

3- التحديد غير الكامل للشكل الرياضي للنموذج .

المقصود هنا أننا ربما نأخذ علاقة وندرسها على أنها علاقة خطية ولكنها في الواقع علاقة غير خطية ، أو نحذف معادلة ونكتفي بمعادلة واحدة ، فالظواهر الإقتصادية هي أكثر تعقيداً مما يمكن أن توضحه معادلة واحدة (Single Equation) ، بغض النظر عن عدد المتغيرات التوضيحية التي تحتويها المعادلة الواحدة ، وفي معظم الحالات فإن عدداً من المتغيرات يقرر أنياً عن طريق نظام من المعادلات .

4- أخطاء التجميع .

عالباً ما تستعمل بيانات مجموعية أو كلية مثل الإستهلاك المجموعي أو الكلي والدخل المجموعي أو الكلي ، والتي فيها نضيف حجوم للمتغيرات مثلاً دالة الإنتاج لأي صناعة تقوم بجمع عناصر الإنتاج والإنتاج للمنظمين غير المتشابهين ، إن التغيرات (changes) في توزيع الإنتاج الكلي بين الشركات مهمة في تقرير الإنتاج الكلي .

وعلى كل حال فإن مثل هذه المتغيرات التوزيعية هي غالباً مفقودة في الدالة ، هناك انواع أخرى من التجميع تسبب أخطاء في العلاقة ، مثلاً التجميع على أساس المقطع العرضي (Cross - section) الخ .

5- أخطاء القياس .

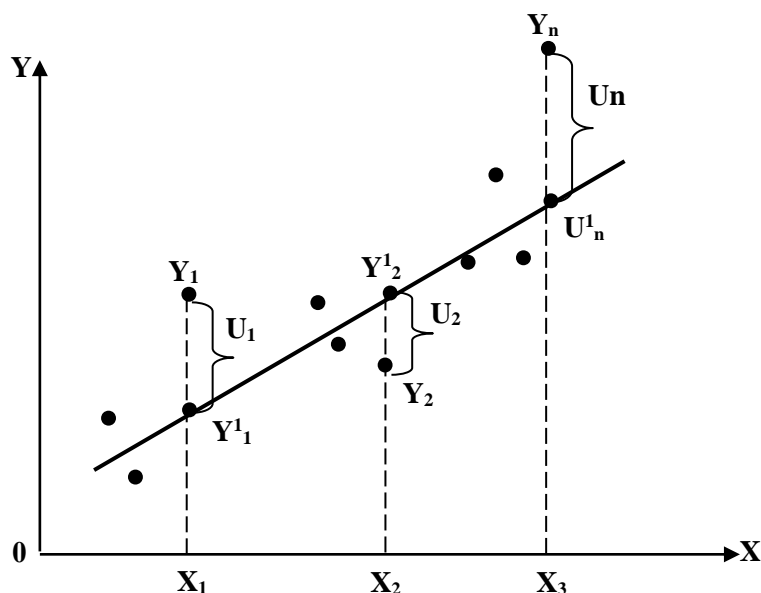
إن إنحراف نقاط المشاهدة عن خط الإنحدار المستقيم ربما يكون سببه أخطاء في القياس هي حتمية بسبب طرق جمع البيانات ومعاملة المعلومات الإحصائية ، إن مصادر الأخطاء الأربعة الأولى تصور لنا شكل المعادلة خطأ ، وعادةً يشار لها (الى هذه الأخطاء) أنها أخطاء المعادلة (Error of Equation) ، والمصدر الخامس للأخطاء يدعى خطأ القياس أو خطأ المشاهدة (Error of Measurment) ، وعادةً فإن هذين النوعين من الأخطاء يكونان موجودان أنياً في المعادلة .

من أجل أن نأخذ في الحساب هذه المصادر المذكورة للأخطاء فإننا ندخل في دوال الإقتصاد القياسي المتغير العشوائي ، والذي يشار اليه عادةً بالحرف (U) ، حيث يدعى صيغة أو حد الخطأ (Error Term) ، أو حد الإضطراب أو الخطأ العشوائي أو الإحتتمالي (Stochastic or Random Disturbance) للدالة ، بإدخال المتغير العشوائي في الدالة ، فإن النموذج يكون نموذجاً إحتمالياً بهذا الشكل :

$$Y_i = (b_0 + b_1 X_i) + (U_i) \dots \dots \dots (2-2-5)$$

فالعلاقة التي تربط بين المتغيرات الداخلة في العلاقة تنقسم الى جزئين أو قسمين :

الجزء الأول يعبر عنه بالخط المستقيم والجزء الثاني يعبر عنه عن طريق المتغير العشوائي (U) ، إن معنى هذين الجزئين ربما يوضح بالنظر الى الشكل (2-5) .



شكل (2-5)

إن شكل الانتشار البياني (2-5) للملاحظات يعبر عن العلاقة الحقيقية بين المتغير (Y) والمتغير (X) ، الخط المستقيم يعبر عن الجزء التام للعلاقة ، وإنحراف المشاهدات عن الخط المستقيم تعبر عن الجزء العشوائي في العلاقة . عندما لا يكون هناك خطأ في النموذج فإننا سنلاحظ أن النقاط على الخط المستقيم (Y_1 و Y_2 و Y_3 ... و Y_n) هي مرافقة لوضع المتغير (X) في (X_1, X_2, \dots, X_n) ولكن بسبب وجود المتغير العشوائي نلاحظ أن (Y_1 و Y_2 و Y_3 ... و Y_n) ترافق أوضاع المتغير (X) في (X_1 و X_2 ... و X_n) . إن هذه النقاط تنحرف عن خط الإنحدار (Regression Line) بالكميات (U_1, U_2, \dots, U_n) عندما يكون (U_i) يعبر عن الخطأ المعياري الذي يرافق المتغير (Y_i) ، بعبارة أخرى فإن قيم المتغير (Y) التي تقابل أو ترافق قيم المتغير (X) ستكون على المعدل تقع على الخط المستقيم ، ولكن كل قيمة فردية للمتغير (Y_i) سوف تنحرف عن الخط وهذا يعتمد على قيمة (U_i) ، ولذلك فإن كل ($i = 1, 2, 3, \dots, n$) (Y_i) يمكن أن يعبر عنها بصيغة عنصرين الأول بسبب المتغير (X) والعنصر الثاني بسبب تأثير الخطأ المعياري (U_i) .

$$Y_i = b_0 + b_1 X_i + U_i$$

$$[\text{الإنحرافات العشوائية}] + [\text{الإنحرافات المنتظمة}] = [\text{الإنحراف في } Y_i]$$

أو

$$[\text{الإنحراف غير الموضح}] + [\text{الإنحراف الموضح}] = [\text{الإنحراف في } Y_i]$$

إن العنصر الأول في داخل الأقواس يعبر عن الإنحراف في (Y) موضحاً عن طريق التغيرات في (X) ، والجزء الثاني يعبر عن الإنحراف غير الواضح بأي عنصر محدد ، وهذا يعني أن الأنحراف في (Y) سببه التأثير العشوائي (U) .

إن معنى المتغير العشوائي (U) يبدو مرتبطاً بعبارة (مع بقاء الأشياء الأخرى ثابتة " Ceteris paribus ") في النظرية الإقتصادية ، فالنظرية الإقتصادية تفترض أن العلاقات الدالية بين المتغيرات هي علاقة تامة (Exact Relationships) تحت ظروف بقاء الأشياء الأخرى ثابتة .

مثلاً دالة الطلب :

$$Q^d = b_0 + b_1P$$

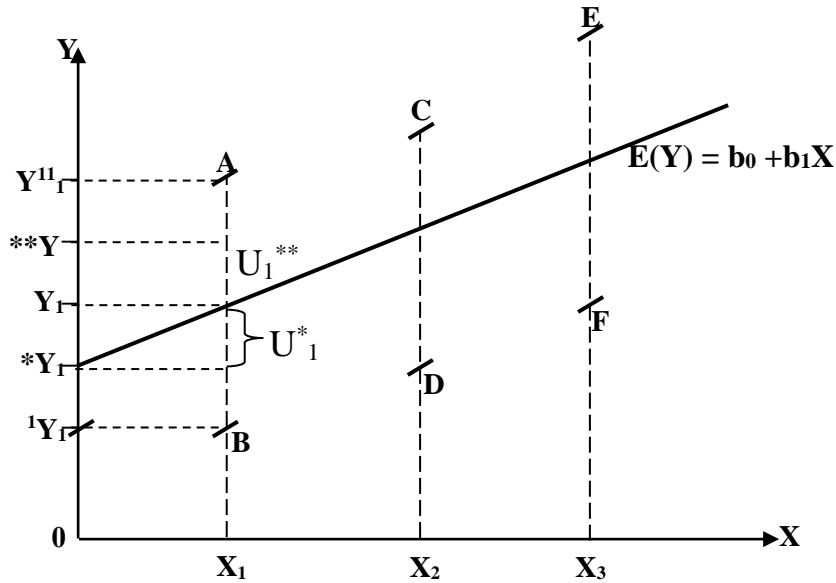
توضح بوساطة النظرية الإقتصادية ، إذ تضمنت دالة الطلب أن الكمية من سلعة معينة هي دالة خطية لسعرها فقط (بقية الأشياء الأخرى تبقى ثابتة ومتساوية) وهذا يعني أن علاقة السعر – الكمية تبقى صحيحة عندما تكون بقية العناصر غير الظاهرة مباشرة أو بوضوح في الدالة (مثلاً الأذواق والدخل وأسعار بقية السلع) تبقى بدون تغيير ، ولكن النظريات هي عبارة عن تبسيط للعلاقات المعقدة الموجودة في العالم الحقيقي أو عالم الواقع . ولذلك فإن عبارة ((بقاء الأشياء الأخرى ثابتة)) نادراً ما تتحقق في الواقع الفعلي ، عندما نجمع بيانات حول الكميات المشتراة من السلعة بأسعار مختلفة ، لا نلاحظ الكميات التي سوف تشتري إذا كانت (بقية الأشياء الأخرى ثابتة) ، ولكننا نلاحظ الكميات التي تم شراؤها بينما كانت أسعار بقية السلع تتغير والدخل والأذواق وبقية العناصر تتغير أو في تغير مستمر . في الإقتصاد القياسي نقرأ العلاقة الحقيقية التي تربط المتغيرات بالصيغة الآتية ، إن المتغير (Y) مرتبط بالمتغير (X) بعلاقة خطية ، مع بقاء الأشياء الأخرى ثابتة .

فإذا كانت بقية العناصر أو العوامل عدا العنصر (X) بقيت ثابتة بدون تغيير ، فإن التغيرات في (Y) ستوضح على نحو كلي من خلال التغيرات في (X) ، ولكن بقية العناصر لا تبقى ثابتة لذلك فإننا ندخل المتغير العشوائي (U) في الدالة من أجل أن نأخذ في الحساب التغيرات الحاصلة في بقية المتغيرات

غير الداخلة في العلاقة على نحو مباشر ، والآن يمكن ان ننظر الى الصيغة النهائية للمعادلة (2-2-5) :

$$Y_i = b_0 + b_1 X_i + U_i \dots\dots\dots(2-2-5)$$

بطريقة أخرى لكل قيمة معطاة للمتغير (Y) والمتغير (X) ربما تأخذ قيماً مختلفة بالإعتماد على القيمة المعينة للمتغير العشوائي (U) (سالبة أو موجبة) التي يأخذها هذا المتغير لكل قيمة من (X) يقابلها توزيع قيم مختلفة للمتغير العشوائي ولذلك قيم للمتغير (Y) ، إن هذا الوضع يوضحه الشكل (3-5) :



شكل (3-5)

مثلاً اذا كان سعر السلعة يساوي (X₁) فإن الكمية التي ستعرض من السلعة بهذا السعر ربما ستأخذ أية قيمة بين (Y₁¹) و (Y₁¹¹) بالإعتماد على قيمة (U) في هذه الفترة .

فمثلاً اذا كان هناك نقص في عدد سواقي الشاحنات أو إنقطاعاً في التيار الكهربائي الذي يؤخر إستلام وتسليم السلعة (هذه الأوضاع هي أمثلة على الحوادث الحاصلة بالصدفة) ، فإن الكمية سوف لا تكون (Y₁) كما توضح ذلك

المعادلة الخطية ، ولكن كمية أصغر (Y_1^*) ، وذلك بسبب العوامل المذكورة أعلاه والتي تعطي قيمة لـ (U) هي (U_1^*) للمتغير العشوائي . من ناحية أخرى اذا كان هناك إشاعة أو توقع إن الأسعار ستتخفض للسلع البديلة أو أن منتج جديد سيدخل السوق ، فإن المنتجين للسلعة في مثالنا سيعرضون كل الخزين منها لديهم في السوق (الكميات التي كان من الممكن عرضها في المستقبل) ، لذلك في مستوى السعر (X_1) الكمية المعروضة من السلعة ستكون (Y_1^{**}) ، وذلك بسبب التغيير في التوقعات التي تعطي قيمة للمتغير العشوائي (U) تساوي (U_1^{**}) .

من أجل تقدير المعلمات (parameters) (b_1, b_0) فإننا بحاجة الى مشاهدات حول المتغير (X) والمتغير (Y) والمتغير العشوائي (U) ، ولكن المتغير (U) لا يمكن مشاهدته مثل بقية المتغيرات التوضيحية ، وكما سنرى نستطيع الحصول على تقدير لقيم (U) بعد تقدير خط الإنحدار وحساب الإنحرافات عن خط الإنحدار ، ولذلك من أجل تقدير الدالة :
فإننا يجب أن نقدر قيم المتغير (U) ، وهذا يعني أننا يجب أن نعمل أو نضع بعض الإفتراضات (Assumptions) حول شكل توزيع المتغير (U_i) (المتوسط الحسابي والتباين والتباين المشترك) ، هذه الإفتراضات هي تقديرات للقيم الحقيقية غير المشاهدة للمتغير (U_i) .

3-5 إفتراضات نموذج الإنحدار الخطي الإحتمالي .

إن نموذج الإنحدار الخطي يعتمد على إفتراضات معينة ، وبعض هذه الإفتراضات تتعلق بتوزيع المتغير العشوائي (U) ، وبعضها الآخر حول العلاقة بين المتغير العشوائي (U) والمتغيرات التوضيحية وبعضها الآخر يتعلق بالعلاقة بين المتغيرات التوضيحية نفسها .

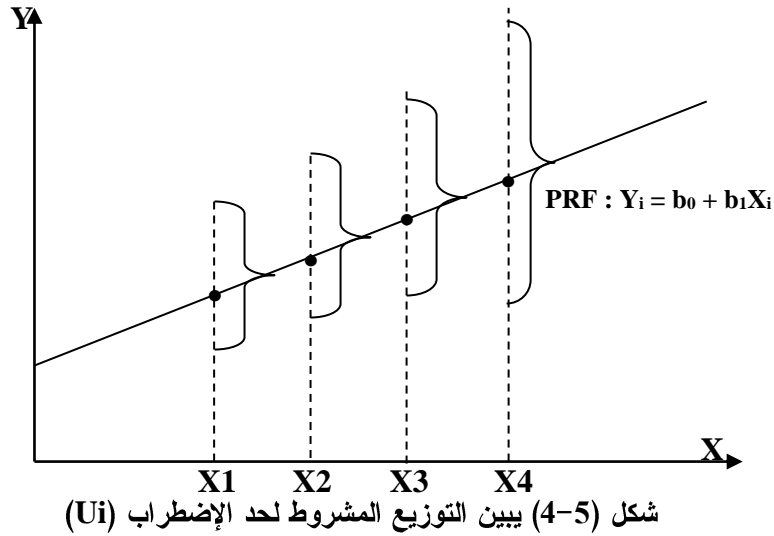
1- الافتراض الأول :

إن (U_i) هو متغير عشوائي حقيقي ، إن القيمة التي من الممكن أن يأخذها المتغير (U_i) في فترة واحدة تعتمد على الصدفة (chance) فربما تكون موجبة أو سالبة أو صفراً ، إن كل قيمة لـ (U_i) لها نسبة إحتمال (probability) في الحدوث في أي مثال ممكن .

وبصيغة المعادلة نقول :

$$E(U_i|X_i) = 0 \dots\dots\dots (1-3-5)$$

وبالكلمات ينص ينص هذا الافتراض على أن القيمة المتوقعة المشروطة للمتغير العشوائي (U_i) (مشروطة بقيمة معطاة لـ "X" هي صفراً ، وهندسياً فإن هذا الافتراض يمكن أن يصور كما في الشكل (3-5) الآتي :



إن الشكل (4-5) يبين عدداً قليلاً من قيم المتغير المستقل (X) وقيم المتغير المعتمد (Y) التي تناظرها من المجتمع الإحصائي للظاهرة ، وكما يبدو في الشكل ، فإن كل قيمة لـ (Y) في المجتمع الإحصائي تناظرها قيمة معطاة لـ (X) ، وتلك القيمة لـ (Y) توزع حول الوسط الحسابي (الذي رسم بصيغة

دائرة داخلها نقطة فوق دالة إنحدار المجتمع الإحصائي) سوف تقع بعض قيم (Y) سوف تقع فوق قيمة الوسط أو المتوسط الحسابي وبعضها دون أو تحت قيمة الوسط الحسابي ، إن هذه المسافات للنقاط فوق وتحت قيم المتوسط الحسابي هي قيم (U_i) والذي تتطلبه المعادلة (2-2-5) هو أن قيمة الوسط الحسابي لهذه الانحرافات (Deviations) المناظرة الى أية قيمة معطاة لـ (X) يجب أن يكون صفراً .

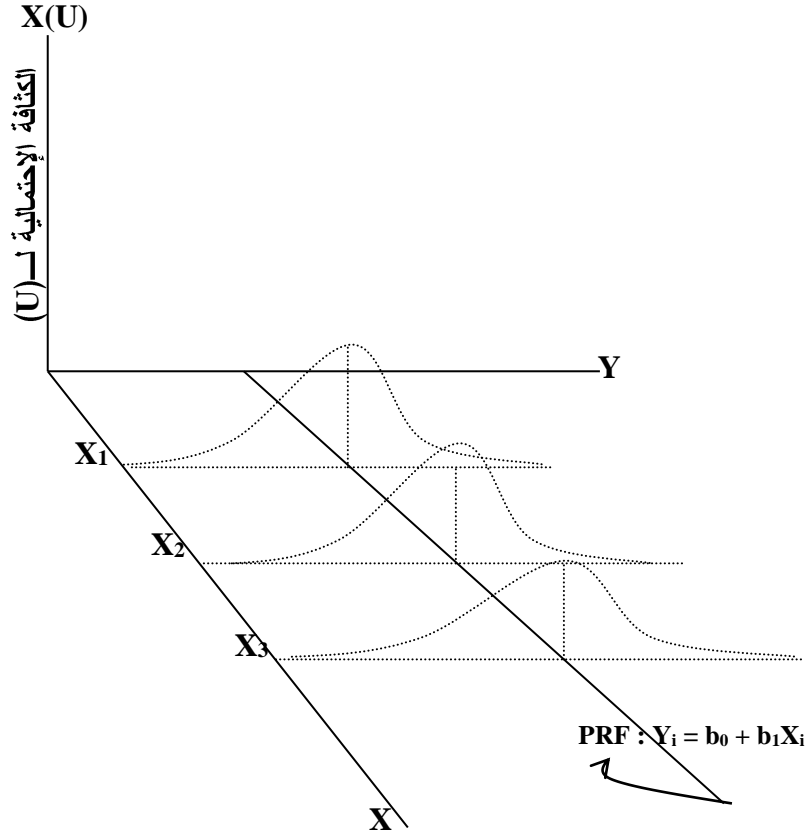
2- الافتراض الثاني :

إن تباين (Variance) المتغير العشوائي (U_i) ثابت في كل فترة وبصيغة المعادلة نجد أن :

$$\begin{aligned} Var(U_i | X_i) &= E[U_i - E(U_i)]^2 \\ &= E(U_i^2) \text{ بسبب الافتراض الأول} \\ &= \sigma^2 \dots (2-3-5) \end{aligned}$$

عندما تكون عبارة (Var) تعني التباين (Variance) إن المعادلة (2-3-5) تنص على أن تباين المتغير (U_i) لكل (X_i) ذلك هو التباين المشروط لـ (U_i) هو رقم موجب ثابت يساوي (σ²) .

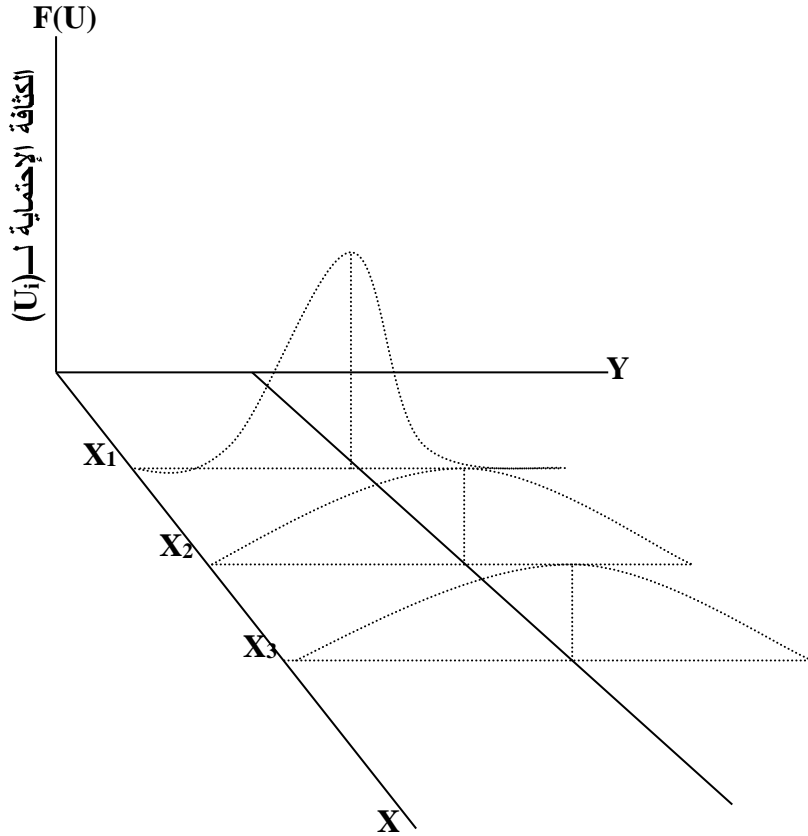
وفنياً فإن المعادلة (2-3-5) تعبر عن افتراض ثبات تباين المتغير العشوائي (Homoscedasticity) ، بعبارة أخرى فإن المعادلة (2-3-5) تعني أن بيانات (Y) في المجتمع الإحصائي المناظرة لقيم مختلفة من (X) يكون لقيم (Y) التباين نفسه ، وفي الشكل البياني (4-5) يبدو هذا الوضع :



شكل (5-5) يبين ثبات تباين المتغير العشوائي
(Homoscedasticity)

وهكذا فإن تباين المتغير العشوائي (U_i) حول وسطه الحسابي ثابت في كل قيم المتغير (X). . بعبارة أخرى لكل قيم (X) فإن قيم المتغير (U) توضح التشتت نفسه حول وسطها الحسابي . في الشكل (5-3) ، فإن هذا الافتراض يوضح الحقيقة التي تقول إن القيم التي يمكن أن يأخذها المتغير (U) تقع ضمن الحدود نفسها بغض النظر عن قيمة (X) . فعندما تكون عند قيمة (X_1) فإن المتغير العشوائي (U) يمكن أن يأخذ قيمة ضمن المدى (AB) وعند قيمة (X_2) فإن المتغير العشوائي (U) يمكن أن يأخذ أية قيمة ضمن المدى ($C.D$) والذي يساوي (AB) وهكذا .

ولكن في حالة زيادة تباين المتغير المعتمد (Y) [شاهدات المجتمع الإحصائي] كلما يزداد (X)، وهي حالة تسمى إختلاف التباين (Heteroscedasticity) ولتوضيح هذه الحالة نستعين بالشكل (5-6) الآتي :



شكل (5-6) يبين إختلاف تباين المتغير العشوائي
(Heteroscedasticity)

إذا أخذنا الشكل (5-6) عندما يتغير تباين المتغير (Y) كلما يزداد (X). وهذا الوضع يسمى إختلاف أو عدم ثبات تباين المتغير العشوائي وبالمصطلح فإن هذا الوضع يعبر عنه بالمعادلة الآتية :

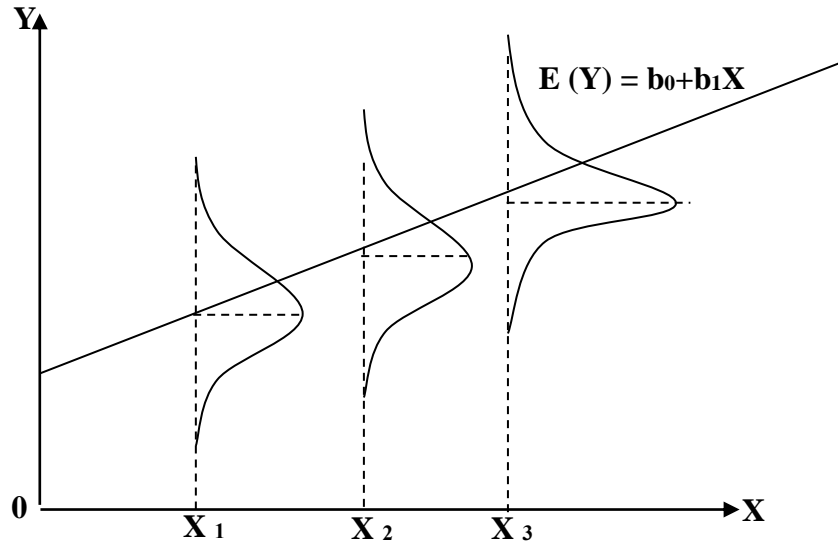
$$Var(U_i | X_i) = \delta_i^2 \dots \dots \dots (3-3-5)$$

إن إضافة (i) الى (σ^2) تؤثر أن تباين (Y) للمجتمع الإحصائي لم يعد ثابتاً .

ومن أجل أن نبين الفرق بين الوضعين بوضوح ، لنجعل (Y) تعبر عن الإنفاق الإستهلاكي الأسبوعي و (X) تعبر عن الدخل الأسبوعي ، إن الشكلين (5-5) (6-5) يبينان أنه كلما يزداد الدخل فإن معدل الإنفاق الإستهلاكي يزداد أيضاً ، ولكن في الشكل (5-5) نجد أن تباين الإنفاق الإستهلاكي يبقى نفسه عند كل مستويات الدخل ، بينما في الشكل (6-5) نجد أن تباين الإنفاق الإستهلاكي يزداد مع زيادة الدخل .

3- الإفتراض الثالث .

إن المتغير العشوائي (U_i) له توزيع طبيعي (Normal Distribution) إن قيم المتغير العشوائي (لكل قيمة من X_i) لها شكل توزيع طبيعي شبيه بشكل الجرس حول وسطها الحسابي ، والشكل (7-5) الآتي يوضح هذا الإفتراض .



شكل (7-5)

إن الإفتراضات السابقة حول سلوك (توزيع) قيم المتغير العشوائي (U_i) يمكن تلخيصها بالتعبير الآتي :

$$U \sim N(0, \sigma_u^2)$$

4- الإفتراض الرابع .

إن المتغير العشوائي (U) مستقل عن المتغيرات التوضيحية وهذا يعني أن المتغير العشوائي غير مرتبط بقيم المتغيرات التوضيحية ، إذ إن المتغير العشوائي (U) وقيم المتغيرات التوضيحية X_1, X_2, \dots, X_n لا تميل للتغير معاً أي أن التباين بينهما يساوي صفراً .

وبصيغة المعادلة فإن هذا الإفتراض يكون كما يأتي :

$$Cov(U_i, X_i) = E[U_i - E(U_i)][X_i - E(X_i)] = 0 \dots (4-3-5)$$

ينص الإفتراض الرابع على أن حد الإضطراب (U) والمتغير

التوضيحي (X) غير مرتبطان ، إن مبرر هذا الإفتراض كما يأتي :

عندما عرضنا دالة إنحدار المجتمع الإحصائي (PRF) ، كما في المعادلة (4-3-2) ، إفتراضنا أن (X) و (U) [الذي ربما يعبر عن تأثير كل المتغيرات المحذوفة] لهما تأثيرين منفصلين على المتغير المعتمد (Y) . ولكن إذا كان (X) و (U) مرتبطان فليس من الممكن تقويم تأثيرهما الفردي على المتغير المعتمد (Y) .

وهكذا إذا إرتبط (X) و (U) إيجابياً فإن (X) يزداد عندما يزداد (U)

وكذلك فإن (X) يتناقص عندما يتناقص (U) .

وبالطريقة نفسها إذا كان (X) و (U) مرتبطان سلبياً ، فإن (X) يزداد

عندما يتناقص (U) وينخفض أو يتناقص عندما يزداد (U) . وفي كلا الحالتين

من الصعوبة جداً عزل تأثير (X) وتأثير (U) على المتغير المعتمد (Y) .

إن الإفتراض الرابع هذا يتحقق تلقائياً إذا كان (X) متغيراً غير عشوائي أو غير إحتمالي . إن نموذج الانحدار الخطي الذي يستوفي هذه الإفتراضات الأربعة السابقة يعرف بأنه نموذج الانحدار الكلاسيكي أو يدعى نموذج الانحدار الخطي العام . إنه نموذج كلاسيكي بمعنى أنه طور لأول من قبل كوز (Gauss) عام (1821) ومنذ ذلك التاريخ قد أستعمل بوصفة قاعدة أو معياراً تقارن به نماذج الانحدار التي لا تتحقق فيها الإفتراضات الأربعة لكوز (Gaussidn).

5- الإفتراض الخامس :

إن المتغيرات التوضيحية تقاس بدون خطأ (Errors) . إن المتغير (U) يغطي تأثير المتغيرات المحذوفة ، ويمكن أيضاً أن يغطي أخطاء القياس للمتغير المعتمد . وهذا يعني أننا نفترض أن المتغيرات التوضيحية حرة من الخطأ بينما قيم المتغير المعتمد لنفترض (Y) ربما تحتوي على أخطاء القياس أو ربما لا تحتوي على أخطاء القياس .

6- الإفتراض السادس :

إن المتغيرات التوضيحية غير مرتبطة خطياً ببعضها البعض على النحو التام .

إذا كان هناك أكثر من متغير توضيحي واحد في العلاقة ، فإننا نفترض عدم وجود علاقة تامة بين تلك المتغيرات . فإذا كانت العلاقة موجودة بين المتغيرات التوضيحية ، فإن هذا الوضع يدعى مشكلة الارتباط الخطي المتعدد (Multicollinearity) .

7- الإفتراض السابع :

إن المتغيرات الاقتصادية الكلية أو المجموعية يجب أن يكون تجميع بياناتها على نحو صحيح . عادة فإن المتغيرات (X) ، (Y) هي متغيرات كلية أو مجموعية تعبر عن حاصل جمع وحدات فردية . مثلاً في حالة الإستهلاك

$$C = b_0 + b_1 Y + U$$

(C) هو حاصل جمع مصروفات كل المستهلكين و (Y) هو حاصل جمع دخول الأفراد . وهكذا من المفروض أن يستخدم أسلوب تجميعي مناسب .
8- الافتراض الثامن :

إن توزيع قيم المتغير المعتمد (Y_i) تأخذ شكل التوزيع الطبيعي (Normal Distribution) . إن شكل توزيع قيم المتغير المعتمد تقرر بوساطة شكل توزيع المتغير العشوائي (U_i) والذي هو شكل توزيع طبيعي كما أن (b_1, b_0) هي معلمات ثابتة لا تؤثر على توزيع قيم المتغير المعتمد (Y_i) فضلاً عن أن قيم المتغيرات التوضيحية (X_i) قد وضعت قيماً ثابتة حسب الافتراض الخامس . ولذلك فإنها لا تؤثر على شكل توزيع قيم المتغير المعتمد (Y_i) .

5-4 : معيار المربعات الصغرى والمعادلات الإعتيادية للمربعات الصغرى (OLS)

لحد الآن قد أكملنا العمل المتضمن للمرحلة الأولى لأي بحث إقتصادي قياسي تطبيقي ويشكل أكثر وضوحاً ، فإننا قمنا بتحديد النموذج وإفترضاته على نحو مباشر . فالخطوة اللاحقة أو التالية هي تقدير النموذج ، وهذا يعني حساب القيم الرقمية لمعلمات النموذج (Paramcters) للعلاقة الخطية :

$$Y_i = b_0 + b_1 X_i + U_i$$

هذه العلاقة تكون صحيحة للمجتمع الإحصائية (Population) لقيم المتغيرات (X) و (Y) ، لذلك نستطيع أن نحصل على قيم رقمية (Numerical Values) للمعلمات (b_0) ، (b_1) فقط إذا كان لدينا قيم للمتغيرات (X) ، (Y) ، (U) وهذه القيم تشكل المجتمع الإحصائي لهذه المتغيرات . ولكن بسبب أنه من غير الممكن عملياً أن نلجأ إلى الحصول على عينة (A sample) للقيم المشاهدة لـ (X) و (Y) وتحدد توزيع المتغير العشوائي (U) ، ثم نحاول

الحصول على تقديرات للمعلومات الحقيقية في العلاقة الاقتصادية . وهذا يمكن أن نعمله عن طريق رسم خط الانحدار من خلال مشاهدات العينة الإحصائية ، والذي نعهده تقديراً أو تقريباً لخط الانحدار الحقيقي .

إن العلاقة الحقيقية بين (X) و (Y) هي :

$$Y_i = b_0 + b_1 X_i + U_i$$

إن خط الانحدار الحقيقي هو :

$$E(Y_i) = b_0 + b_1 X_i$$

كما أن العلاقة المقدرة (The Estimated Relationship) هي :

$$\hat{Y}_i = \hat{b}_0 + \hat{b}_1 X_i + e_i$$

وخط الانحدار المقدر (The Estimated Regression Line) هو :

$$\hat{Y}_i = \hat{b}_0 + \hat{b}_1 X_i$$

عندما يكون :

$$\hat{Y}_i = \text{القيمة المقدرة لـ } (Y) \text{ مع قيمة محددة لـ } (X) .$$

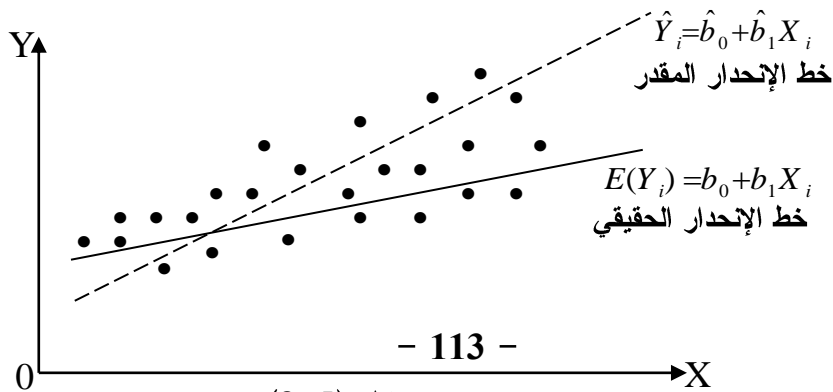
$$\hat{b}_0 = \text{القيمة المقدرة لمعلمة التقاطع } b_0 \text{ الحقيقية .}$$

$$\hat{b}_1 = \text{القيمة المقدرة لمعلمة الميل } b_1 \text{ الحقيقية .}$$

$$e = \text{القيمة المقدرة للقيمة الحقيقية للمتغير العشوائي } (u) .$$

إن خط الانحدار المقدر وخط الانحدار الحقيقي يوضحهما الشكل (5-8)

الآتي :



ففي الشكل (5-8) نجد حالة العرض (Supply Function) ، ومن أجل أن نحسب القيم الرقمية للمعلمات الحقيقية (True Parameters) (b_0) و (b_1) ، يجب أن نحصل قيم للكميات المعروضة في كل مستوى من مستويات الأسعار وهذا طليعاً غير ممكن . لذلك نلجأ إلى عينة من الأسعار والكميات المشاهدة في السوق خلال فترة معينة من الزمن ونحاول أن نحصل على أفضل تقدير ممكن لدالة العرض .

إن العقبة في هذا الأسلوب هي أنه في كل عينة كعينة من الممكن أن نحصل على عدد غير محدود من خطوط الإنحدار المقدرة ، وذلك بإعطاء قيم مختلفة للمعلمات (b_0) و (b_1) .

كما لاحظنا في الفصل الرابع ، فإن دالة إنحدار المجتمع الإحصائي (PRF) هي دالة غير مشاهدة على نحو مباشر ، تقوم بتقديرها من دالة إنحدار العينة الإحصائية . ولكن السؤال المهم هو كيف يمكن أن تقرر دالة إنحدار العينة الإحصائية ؟

إذا استرجعنا نموذج الإنحدار الخطي بمتغيرين لعينة إحصائية (SRF) نستطيع أن نكتب :

$$Y_i = \hat{b}_0 + \hat{b}_1 X_i + e_i \dots \dots \dots (1-4-5)$$

$$= \hat{Y}_i + e_i \dots \dots \dots (2-4-5)$$

عندما تكون (\hat{Y}_i) قيمة مقدرة لـ (Y_i) [وسط حسابي مشروع]

نستطيع أن نفرض المعادلة (2-4-5) بصيغة بديلة :

$$e_i = Y_i - \hat{Y}_i$$

$$=Y_i - \hat{b}_0 - \hat{b}_1 X_i \dots\dots\dots (3-4-5)$$

وهذه المعادلة الأخيرة يتبين أن (e_i) [البواقي Residual] هي ببساطة الفروقات بين القيم الفعلية والقيم المقدرة لـ (Y) والآن إذا أعطينا عدد (N) من أزواج من المشاهدات حول (Y) و (X) ، فإننا نرغب في تقرير دالة إنحدار العينة (SRF) بإسلوب قدر الإمكان قريباً من القيم الفعلية لـ (Y) . ولهذا الغرض ربما نتبنى المعيار الآتي :

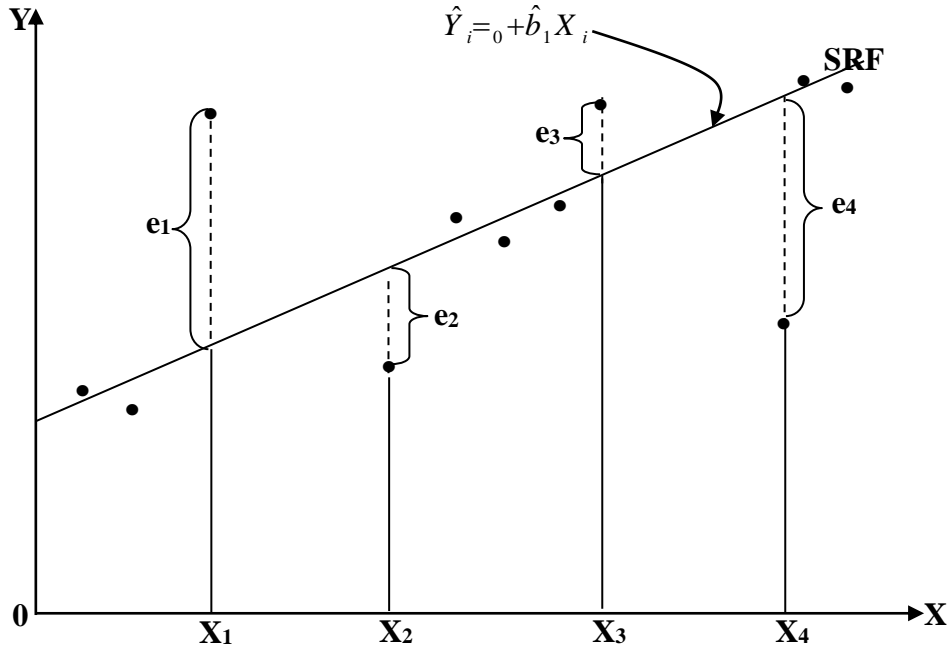
يتم إختيار دالة إنحدار العينة الإحصائية (SRF) بطريقة يكون فيها مجموع البواقي :

$$\sum e_i = \sum (Y_i - \hat{Y})$$

أصغر ما يمكن .

فإذا تبينا هذا المعيار في تصغير مجموع البواقي $(\sum e_i)$ فإن الشكل (4-5) يبين أن البواقي (e_2) و (e_3) وكذلك (e_1) و (e_2) يحصلون على الوزن نفسه في مجموع البواقي $(e_1+e_2+e_3+e_4)$ على الرغم من أن البواقي الإثنين الأولى أكثر إقتراباً إلى دالة إنحدار العينة الإحصائية (SRF) مما هو بالنسبة للبواقي الأخيرين .بعبارة أخرى فإن كل البواقي تحصل على الأهمية المتساوية بغض النظر عن حجم إبتعاد أو إنتشار المشاهدات الفردية حول خط الإنحدار .وننتيجة لهذا فإنه من الممكن أن يكون المجموع الجبري لـ (e_i) صغيراً أو صفراً . على الرغم من أن (e_i) منتشراً على نحو واسع حول دالة إنحدار العينة الإحصائية (SRF).ومن أجل أن نرى هذا لنجعل $(e_1+e_2+e_3+e_4)$ في الشكل (9-5) تأخذ القيم $(-10,+2,-2,10)$.

إن المجموع الجبري لهذه البواقي هو صفر على الرغم من أن (e_1) و (e_4) تنتشر بإتساع كبير حول دالة إنحدار العينة الإحصائية مما إنتشر به (e_2) و (e_3) .



شكل (5-9) يبين معيار المربعات الصغرى

نستطيع أن نتجنب هذه المشكلة إذا تبيننا معيار المربعات الصغرى
(The Least – Squares Criterion) الذي ينص على أن دالة إنحدار العينة
الإحصائية (SRF) يمكن أن تثبت بالطريقة الآتية :

$$\sum ei^2 = \sum (Y_i - \hat{Y}_i)^2$$

$$= \sum (Y_i - \hat{b}_0 - \hat{b}_1 X_i)^2 \dots \dots \dots (4-4-5)$$

صغيراً إلى الحد الممكن . عندما يكون (e_i^2) تربيع البواقي من خلال تربيع (e_i)
فإن هذه الطريقة تعطي وزناً أكبر للبواقي (e_1) و (e_4) مما تعطيه للبواقي
 (e_2) و (e_3) في الشكل (5-9) .

كما لاحظنا سابقاً في ظل معيار مجموع أصغر الانحرافات $(\sum e_i)$ فإن المجموع يمكن أن يكون صغيراً حتى ولو أن (e_i) ينتشر بإتساع حول (SRF). ولكن هذا غير ممكن في ظل أسلوب المربعات الصغرى (Least-Squares) وذلك لأنه عندما يكون (e_i) كبيراً (بالقيمة المطلقة) فإن $(\sum e_i^2)$ يكون أكبر. وهناك مبرر آخر لصالح طريقة المربعات الصغرى يكمن في حقيقة أن المعلومات المقدرة بهذه الطريقة تمتلك بعض الصفات الإحصائية المرغوبة .

من الواضح أن :

$$\sum e_i^2 = f(\hat{b}_0, \hat{b}_1) \dots \dots \dots (5-4-5)$$

وهذه المعادلة تعني أن مجموع تربيع البواقي هو دالة للمعاملات المقدرة (b_0) و (b_1) بالنسبة لأي مجموعة بيانات معطاه تختار قيماً مختلفة لـ (b_0) و (b_1) سوف تعطي بواقي مختلفة ، ولذلك فإن قيم $(\sum e_i^2)$ ستكون مختلفة .

إن مبدأ المربعات الصغرى يختار \hat{b}_0, \hat{b}_1 بالنسبة لأي عينة بطريقة يكون فيها مجموع تربيع البواقي $(\sum e_i^2)$ صغير أو أصغر ما يمكن ، ولكن كيف يمكن عمل ذلك ؟ إن هذا عبارة عن تمرين في حساب التفاصيل . إن عملية التفاصيل تنتج الصيغ الآتية لتقدير المعلمات (b_0) و (b_1) :

$$\sum Y_i = N\hat{b}_0 + \hat{b}_1 \sum X_i \dots \dots \dots (6-4-5)$$

$$\sum Y_i X_i = \hat{b}_0 \sum X_i + \hat{b}_1 \sum X_i^2 \dots \dots \dots (7-4-5)$$

عندما يكون (N) حجم العينة (أي عدد المشاهدات) ، إن هذه المعادلات الآتية (Simultaneous Equations) تعرف بوصفها المعادلات الطبيعية أو الإعتيادية (Normal Equations) .

إن هذه هذه المعلمات المقدرة (\hat{b}_0) و (\hat{b}_1) التي حصلنا عليها نعرف بمقدرات المربعات الصغرى ، وذلك لأنها أشتقت من مبدأ المربعات الصغرى ، وتتصف هذه المعلمات المقدرة بالصفات الآتية :

1. إنها تعرض فقط بصيغة كميات يمكن مشاهدتها من عينة إحصائية .
2. إنها مقدرات نقطة ، وهذا يعني إذا أعطينا عينة إحصائية ، فإن كل معلمة مقدرة سوف توفر قيمة واحدة فقط للمعلمة الملائمة للمجتمع الإحصائي .

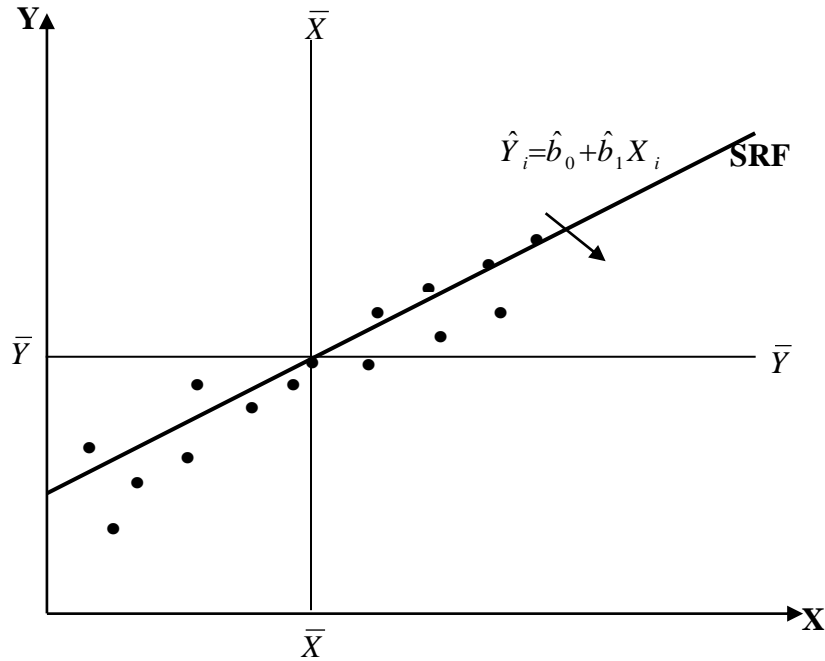
وعندما يتم الحصول على المعلمات المقدرة من البيانات المتوافرة فإن خط إنحدار العينة يمكن أن يرسم أو يوفق بسهولة . وهكذا فإن خط الإنحدار الذي حصلنا عليه يتصف بالخواص الآتية :

1. إن خط إنحدار العينة يمر عبر المتوسطات الحسابية لـ (Y) ولـ (X) .

وهذا واضح من المعادلة الآتية :

$$\bar{Y} = \hat{b}_0 + \hat{b}_1 \bar{X} \dots \dots (8-4-5)$$

والتي تبدو في الشكل (5-10) الآتي :



شكل (10-5) يبين أن خط إنحدار العينة الإحصائية الذي يمر عبر قيم المتوسطات الحسابية لـ (X) , (Y)

2. إن قيمة الوسط الحسابي لـ (Y) المقدرة (\hat{Y}_i) تساوي قيمة

الوسط الحسابي لـ (Y) الفعلية وذلك لأن :

$$\begin{aligned}\hat{Y}_i &= \hat{b}_0 + \hat{b}_1 X_i \\ &= (\bar{Y} - \hat{b}_1 \bar{X}) + \hat{b}_1 X_i \\ &= \bar{Y} - \hat{b}_1 \bar{X} + \hat{b}_1 X_i \\ &= \bar{Y} - \hat{b}_1 (X_i - \bar{X}) \\ \hat{Y}_i &= \bar{Y} - 0 \\ \bar{\hat{Y}} &= \bar{Y}\end{aligned}$$

5-5 اشتقاق المعادلات الطبيعية

Derivation of The Normal Equations

$$\sum e_i^2 = \sum (Y_i - \hat{Y}_i)^2$$

نعوض عن قيمة (\hat{Y}_i) في المعادلة :

$$\sum e_i^2 = \sum [Y_i - (\hat{b}_0 + \hat{b}_1 X_i)]^2$$

$$\sum e_i^2 = \sum (Y_i - \hat{b}_0 - \hat{b}_1 X_i)^2$$

نصغر المعادلة السابقة بالنسبة الى (\hat{b}_0) و (\hat{b}_1) .

إن الشرط الضروري للتصغير هو أن المشتقات الأولى للدالة

(First Derivatives) تساوي صفراً .

$$\frac{\partial \sum e_i^2}{\partial \hat{b}_0} = 0 \quad \frac{\partial \sum e_i^2}{\partial \hat{b}_1} = 0$$

وللحصول على المشتقات أعلاه نطبق قاعدة دالة الدالة من قواعد

التفاضل وإستناداً الى هذه القاعدة :

إذا كانت : $Y = F(W)$ وأن $W = (F)X$ عندئذ فإن :

$$\frac{dy}{dx} = \frac{dy}{dw} \cdot \frac{dw}{dx}$$

وفي حالة الدالة السابقة لنجعل : $(Y_i - \hat{b}_0 - \hat{b}_1 X_i) = w \leftarrow$

وهكذا نحصل على المشتقة الجزئية بالنسبة الى (\hat{b}_0) :

$$\frac{\partial \sum e_i^2}{\partial \hat{b}_0} = \frac{\partial \sum (Y_i - \hat{b}_0 - \hat{b}_1 X_i)^2}{\partial \hat{b}_0} = 0$$

$$2 \sum (Y_i - \hat{b}_0 - \hat{b}_1 X_i) \cdot (-1) = 0$$

وبالقسمة على (-2) نحصل على المعادلة :

$$\sum (Y_i - \hat{b}_0 - \hat{b}_1 X_i) = 0 \dots\dots\dots (1-5-5)$$

المشتقة الجزئية بالنسبة الى (\hat{b}_1) :

$$\frac{\partial \sum e_i^2}{\partial \hat{b}_1} = \frac{\partial \sum (Y_i - \hat{b}_0 - \hat{b}_1 X_i)^2}{\partial \hat{b}_1} = 0$$

$$2 \sum (Y_i - \hat{b}_0 - \hat{b}_1 X_i) \cdot (-X_i) = 0$$

وبالقسمة على (-2) نحصل على المعادلة :

$$\sum (Y_i X_i - \hat{b}_0 X_i - \hat{b}_1 X_i^2) = 0 \dots\dots\dots (2-5-5)$$

نربط المعادلتين $(1-5-5)$ و $(2-5-5)$ ونقوم بإدخال إشارة الجمع نحصل

$$\sum Y_i - \sum \hat{b}_0 - \sum \hat{b}_1 X_i = 0$$

$$\sum Y_i X_i - \sum \hat{b}_0 X_i - \sum \hat{b}_1 X_i^2 = 0 \quad \text{على:}$$

نطبق قواعد التجميع الإعتيادية نحصل على المعادلات الطبيعية أو الإعتيادية

(Normal Equations) لطريقة المربعات الصغرى الإعتيادية (OLS) :

$$\sum Y_i = \hat{b}_0 n + \hat{b}_1 \sum X_i$$

$$\sum Y_i X_i = \hat{b}_0 \sum X_i + \hat{b}_1 \sum X_i^2$$

وبحل هاتين المعادلتين للوصول الى (\hat{b}_0) و (\hat{b}_1) نحصل على

المعلومات المقدرة لطريقة المربعات الصغرى :

$$\hat{b}_0 = \frac{\sum X_i^2 \sum Y_i - \sum X_i \sum X_i Y_i}{N \sum X_i^2 - (\sum X_i)^2} \dots\dots\dots (3-5-5)$$

$$\hat{b}_1 = \frac{n \sum X_i Y_i - \sum X_i \sum Y_i}{n \sum X_i^2 - (\sum X_i)^2} \dots\dots\dots (4-5-5)$$

واضح أن كل من (\hat{b}_0) و (\hat{b}_1) يمكن أن تقدران من خلال التعويض عن القيم $(n), (\sum X_i), (\sum Y_i), (\sum X_i Y_i), (\sum X_i^2)$ التي نحصل على قيمها من مشاهدات العينة الموجودة في جدول البيانات للعينة الإحصائية .
إن القوانين المذكورة آنفاً قد عرضت بصيغ المشاهدات الأصلية للعينة حول كل من $(Y)(X)$ ، يمكن أن نبين أن المعلمات المقدرة (\hat{b}_0) و (\hat{b}_1) ربما نحصل عليها من خلال القوانين الآتية بصيغ إنحرافات المتغيرات عن وسطها الحسابي :

$$\hat{b}_0 = \bar{Y} - \hat{b}_1 \bar{X} \dots\dots\dots (5-5-5)$$

$$\hat{b}_1 = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sum (X_i - \bar{X})^2} \dots\dots\dots (6-5-5)$$

البرهان

$$\sum (X_i - \bar{X})(Y_i - \bar{Y}) = \frac{(n \sum X_i Y_i - \sum X \sum Y)}{n}$$

1- معلوم أن

$$\sum (X_i - \bar{X})^2 = \frac{n \sum X_i^2 - (\sum X_i)^2}{n}$$

2- ومعلوم أن

3- نعوض في قانون (\hat{b}_1) نحصل :

$$\hat{b}_1 = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sum (X_i - \bar{X})^2} = \frac{\frac{n \sum X_i Y_i - \sum X_i \sum Y_i}{n}}{\frac{n \sum X_i^2 - (\sum X_i)^2}{n}}$$

$$\hat{b}_1 = \frac{n \sum X_i Y_i - \sum X_i \sum Y_i}{n \sum X_i^2 - (\sum X_i)^2}$$

وللحصول على قانون (\hat{b}_0) نقوم بتقسيم المعادلة الطبيعية الأولى على

(n) فنحصل على :

$$\frac{\sum Y_i}{n} = \frac{\hat{b}_0 n}{n} + \frac{\hat{b}_1 \sum X_i}{n}$$

$$\bar{Y} = \hat{b}_0 + \hat{b}_1 \bar{X}$$

$$\hat{b}_0 = \bar{Y} - \hat{b}_1 \bar{X}$$

أو نقول إن خط الإنحدار يمر عبر نقطة تعرف من خلال المتوسطات

الحسابية للمتغيرين (Y) , (X) .

مثال :

لتوضيح إستخدام القوانين المذكورة آنفاً سوف نقدر دالة عرض السلعة

(Z) بإستخدام البيانات في الجدول (1-5) الآتي :

جدول (5-1)

N	العبئة Y_i	السمور X_i	X_i^2	$X_i Y_i$	Y_i ($Y_i - \bar{Y}$)	X_i ($X_i - \bar{X}$)	$X_i Y_i$	$(\hat{Y}_i - Y_i)^2$	$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_i$	$e_i = (Y_i - \hat{Y}_i)$	e_i^2
1	69	9	81	621	6	0	0	0	63.00	6.00	36.00
2	76	12	144	912	13	3	39	9	72.75	3.25	10.56
3	52	6	36	312	-11	-3	33	9	52.25	-1.25	1.56
4	56	10	100	560	-7	1	-7	1	66.25	-10.25	105.06
5	57	9	81	513	-6	0	0	0	63.00	-6.00	36.00
6	77	10	100	770	14	1	14	1	66.25	10.75	115.56
7	58	7	49	406	-5	-2	10	4	56.50	1.50	2.25
8	55	8	64	440	-8	-1	8	1	59.75	-4.75	22.56
9	67	12	144	804	4	3	12	9	72.75	-5.75	30.06
10	53	6	36	318	-10	-3	30	9	53.25	-0.25	0.06
11	72	11	121	792	9	2	18	4	69.50	2.50	6.25
12	64	8	64	512	1	-1	-1	1	59.75	4.25	18.06
N=12	$\Sigma Y_i = 756$	$\Sigma X_i = 108$	$\Sigma X_i^2 = 1020$	$\Sigma X_i Y_i = 6960$	$\Sigma Y_i = 0$	$\Sigma X_i = 0$	$\Sigma X_i Y_i = 1560$	$\Sigma e_i^2 = 48$	$\Sigma \hat{Y}_i = 756.0$	$\Sigma e_i = 0$	$\Sigma e_i^2 = 383.98$

أولاً- بإستخدام قوانين مشاهدات العينة الأصلية :

$$\hat{b}_0 = \frac{\sum X_i^2 \sum Y_i - (\sum X_i)(\sum X_i Y_i)}{n \sum X_i^2 - (\sum X_i)^2} = \frac{(1020)(756) - (108)(6960)}{(12)(1020) - (108)^2}$$

$$\hat{b}_1 = \frac{n \sum X_i \sum Y_i - \sum X_i \sum Y}{n \sum X_i^2 - (\sum X_i)^2} = \frac{(12)(6960) - (756)(108)}{(12)(1020) - (108)^2}$$

$$= \frac{1872}{576} \approx 3.25$$

ثانياً- بإستخدام قوانين إنحرافات المتغيرات عن متوسطاتها الحسابية :

$$\hat{b}_1 = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sum (X_i - \bar{X})^2} = \frac{156}{48} = 3.25$$

$$\hat{b}_0 = \bar{Y} - \hat{b}_1 \bar{X}$$

$$= 63 - (3.25)(9)$$

$$= 33.75$$

وهكذا فإن دالة العرض المقدرة هي :

$$\hat{Y}_i = 33.75 + 3.25X_i$$

المثال الثاني : قدر دالة إنحدار الإنفاق الإستهلاكي العائلي الأسبوعي

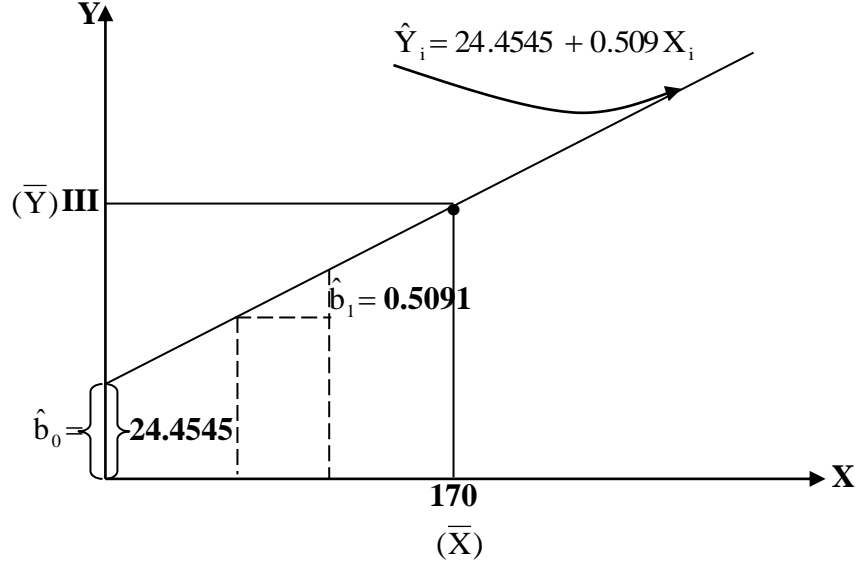
(Y) على الدخل العائلي الأسبوعي (X) من بيانات العينة الإحصائية الآتية :

<u>Y</u>	<u>X</u>
70	80
65	100
90	120
95	140
110	160
115	180
120	200
140	220
155	240
150	260

	Y_i	X_i	$Y_i X_i$	X_i^2	$\frac{x}{X_i - \bar{X}}$	$\frac{y}{X_i - \bar{Y}}$	X^2	XY_i	\hat{Y}_i	$\frac{e}{Y_i - \bar{Y}_i}$
	70	80	5600	640	-90	-41	8100	3690	65.18	4.818
	65	100	6500	10000	-70	-46	4900	3220	75.36	-10.36
	90	120	10800	14400	-50	-21	2500	1050	85.54	4.454
	95	140	13300	19600	-30	-16	900	480	95.72	-0.72
	110	160	17600	25600	-10	-1	100	10	105.90	4.09
	115	180	20700	32400	10	4	100	40	116.09	-1.09
	120	200	24000	40000	30	9	900	270	126.27	-6.27
	140	220	30800	48400	50	29	2500	1450	136.4	3.54
	155	240	37200	57600	70	44	4900	3080	146.6	8.36
	150	260	3900	67600	90	39	8100	3510	156.8	-6.81
المجموع	1110	1700	205500	322000	0	0	33000	16800	1109.9	0
الوسط الحسابي	111	170	—	—	0	0	—	—	111	0

$$\hat{b}_0 = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sum (X_i - \bar{X})^2} = \frac{16800}{33000} = 0.5091$$

$$\begin{aligned} \hat{b}_0 &= \bar{Y} - \hat{b}_1 \bar{X} \\ &= 111 - (0.5091)(170) \\ &= 24.4545 \end{aligned}$$



5-6 : تقدير الدالة التي يكون تقاطعها مع المحور العمودي صفراً .

في بعض الحالات توضح لنا النظرية الإقتصادية علاقات يكون تقاطع دالتها يساوي صفراً . وهذا يعني أن خط الانحدار يمر من خلال نقطة التقاء المحور العمودي مع المحور أو الإحداثي الأفقي ، مثلاً دالة الإنتاج الخطية للمنتجات المصنعة يجب أن يكون لها دالة مع تقاطع يساوي صفراً ، وذلك لأنه عندما يكون الإنتاج صفراً فإن عوامل الإنتاج أيضاً صفراً ففي هذه الحالة يجب أن تقدر الدالة :

$$Y = b_0 + b_1 X + u$$

ولكن هنا نضع قيداً جديداً على الدالة وهو أن $0 = b_0$

لذلك فإن القانون الذي يستخدم لتقدير \hat{b}_1 لهذه الدالة يكون :

$$\hat{b}_1 = \frac{\sum X_i Y_i}{\sum X_i^2}$$

وهذا القانون يتضمن القيم الفعلية للمتغيرات وليس الانحرافات كما في الحالات غير المقيدة بالشرط $0 = b_0$.

5-7 : تقدير المرونات من خط الإنحدار المقدر .

قلنا أن الدالة المقدره :

$$\hat{Y}_i = \hat{b}_0 + \hat{b}_1 X_i$$

هي معادلة الخط الذي يكون تقاطعه مع المحور أو الأحداثي العمودي هو \hat{b}_0 وميله هو \hat{b}_1 هي عبارة عن مشتقة الدالة \hat{Y} بالنسبة إلى X :

$$\hat{b}_1 = \frac{d\hat{Y}}{dX}$$

وهذه المشتقة أو الميل يبين لنا معدل التغيير في (\hat{Y}) الذي يصاحب التغير في (X) بكميات صغيرة جداً . يجب أن واضحاً الآن إذا كانت الدالة المقدره هي دالة خطية للطلب على السلع أو العرض من السلع فإن المعلمة (\hat{b}_1) هي ليست المرونة السعرية ، ولكن عنصر من عناصر تلك المرونة والتي تعرف بالقانون الآتي :

$$n_p = \frac{\frac{dY}{Y}}{\frac{dX}{X}} = \frac{dY}{dX} \cdot \frac{X}{Y}$$

عندما يكون : $n_p =$ المرونة السعرية .

$Y =$ الكمية المطلوبة أو المعروضة .

$X =$ السعر .

يتضح أن المعلمة \hat{b}_1 هي العنصر $\frac{dY}{dX}$ ، لذلك نجد أو نحصل من

الدالة المقدرة معدل للمرونة :

$$\begin{aligned}\eta_p &= \hat{b}_1 \cdot \frac{\bar{X}}{\bar{\hat{Y}}} \\ &= \hat{b}_1 \cdot \frac{\bar{X}}{\bar{Y}}\end{aligned}$$

عندما يكون :

\bar{X} = معدل السرعات والوسط الحسابي لـ X في العينة .

$\bar{\hat{Y}}$ = الوسط الحسابي للقيم المقدرة للمتغير المعتمد Y .

\bar{Y} = الوسط الحسابي للقيم الفعلية للمتغير المعتمد Y .

يجب أن نلاحظ أن $\bar{\hat{Y}} = \bar{Y}$ ، وهذا يعني أن الوسط الحسابي للقيم المقدرة للمتغير المعتمد Y يساوي الوسط الحسابي للقيم الفعلية للمتغير المعتمد Y للعينة ، وذلك لأنه :

$$\hat{Y} = \hat{b}_0 + \hat{b}_1 X_i$$

$$\bar{\hat{Y}} = \hat{b}_0 + \hat{b}_1 \bar{X}$$

$$\hat{b}_0 = \bar{Y} - \hat{b}_1 \bar{X}$$

$$= (\bar{Y} - \hat{b}_1 \bar{X}) + \hat{b}_1 \bar{X}$$

$$= \bar{Y} - \cancel{\hat{b}_1 \bar{X}} + \cancel{\hat{b}_1 \bar{X}}$$

$$\bar{\hat{Y}} = \bar{Y}$$

في مثالنا السابق حول دالة العرض نجد أن المرونة السعرية للعرض هي :

$$\eta_p = (3.25) \frac{\bar{X}}{\bar{\hat{Y}}} = (3.25) \frac{9}{63}$$

$$\approx 0.46$$

الفصل السادس
الإحذار المتعدد

الإحدار المتعدد

1-6 : نموذج ذو متغيرين توضيحيين

Two Explanatory Variables

1-1-6 : المعادلات الطبيعية .

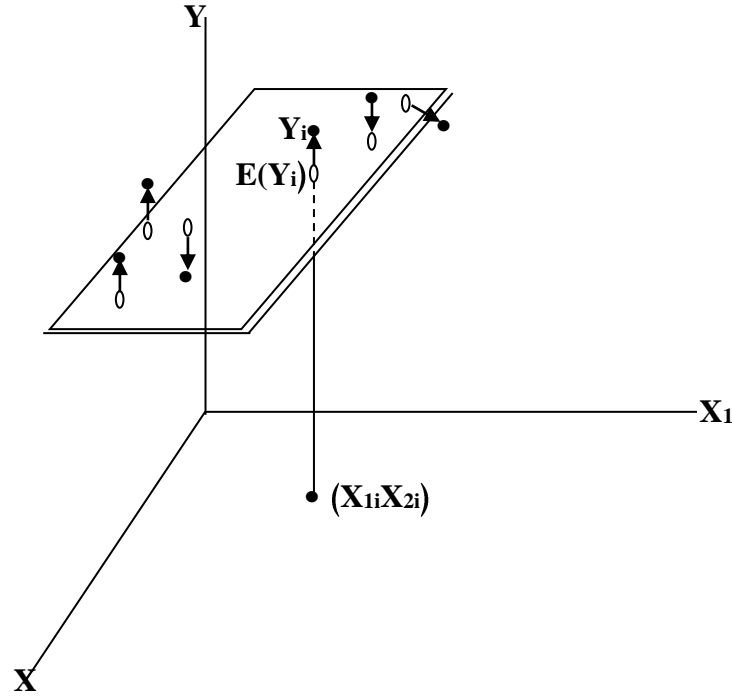
في هذه الحالة يجب أن نوضح النموذج ذو الثلاث متغيرات أحد هذه المتغيرات هو المتغير المعتمد وبقية المتغيرين هما المتغيران المستقلان . باستخدام مثال من نظرية الطلب ، نجد أن النظرية الإقتصادية توضح لنا أن الكمية المطلوبة من سلعة معينة (Y) تعتمد على سعرها (X_1) ودخل المستهلك (X_2) . بالإمكان التعبير عن هذا بصيغة الدالة :

$$Y = f(X_1, X_2)$$

نعلم أن النظرية الإقتصادية لا تحدد لنا الشكل الرياضي لدالة الطلب لذلك نبدأ بحثنا بإفترض إن العلاقة بين (Y) و (X_1) و (X_2) هي علاقة خطية ، ولذلك تكون لدينا دالة الطلب الآتية :

$$Y_i = b_0 + b_1 X_{1i} + b_2 X_{2i} (i=1,2,\dots,n)$$

إن هذه العلاقة هي علاقة تامة (Exact Relationship) كما ذكرنا سابقاً ، ومعناها أن الانحرافات في الكمية المطلوبة توضح على نحو كامل بواسطة سعر السلعة ودخل المستهلك فقط . فإذا كان هذا الشكل للعلاقة هو صحيح فإن أية مشاهدة حول (Y) و (X_1) و (X_2) تعطينا نقطة تقع على المساحة المستوية (aplane) للمتغيرات (Y) و (X_1) و (X_2) .



شكل (6-1) يبين شكل الإنتشار لنقاط الملاحظة حول المساحة المستوية للإحداد
(The Regression Plane)

فإذا جمعنا بيانات عن المشاهدات لهذه المتغيرات خلال مدة زمنية معينة ونقوم برسم نقاط المشاهدات بشكل الإنتشار ، فسوف نلاحظ أن بعض النقاط لا تقع على المساحة المستوية (plane) ، وإن بعضها يقع على المساحة المستوية وإن البعض الآخر سيقع إما فوق المساحة المستوية أو تحتها . إن هذا الإنتشار بسبب عدد من العوامل أو العناصر المحذوفة من الدالة ، فضلاً عن أنواعاً أخرى من الخطأ التي تم شرحها في الفصول السابقة .

إن تأثير مثل هذه العوامل المحذوفة يمكن أخذه في الحساب بوساطة إدخال المتغير العشوائي (u) (Random Variable) في الدالة والتي ستصبح دالة احتمالية (Stochastic Function) .

$$\hat{Y}_i = (\hat{b}_0 + \hat{b}_1 X_{1i} + \hat{b}_2 X_{2i}) + (u_i)$$

العنصر العشوائي العنصر النظامي

على أسس مسبقة نتوقع أن المعلمة (\hat{b}_1) سيكون لها إشارة سالبة ، وكما هو معروف من قانون الطلب ، بينما (\hat{b}_2) من المتوقع أن يكون لهذه المعلمة إشارة موجبة ، وذلك لأن الكمية المطلوبة من السلع الإعتيادية تتغير بالإتجاه نفسه الذي يتغير به الدخل .

إن الافتراضات بالنسبة للإنحدار المتعدد هي الافتراضات نفسها بالنسبة للإنحدار البسيط الذي مر ذكره في الفصل السابق .

بعد تحديد النموذج نقوم بإستخدام عينة إحصائية متكونة من مشاهدات حول (Y) و (X_1) و (X_2) نحصل على تقديرات للمعلمات الحقيقية : b_0 و b_1 و b_2 .

$$\hat{Y}_i = \hat{b}_0 + \hat{b}_1 X_{1i} + \hat{b}_2 X_{2i}$$

عندما تكون :

\hat{b}_0 و \hat{b}_1 و \hat{b}_2 هي تقديرات للمعلمات الحقيقية b_0 و b_1 و b_2 للعلاقة . وكما مر في الإنحدار البسيط ، فإن التقديرات يمكن الحصول عليها بواسطة تصغير (Minimising) مربع الإنحرافات أو مربع البواقي .

$$\sum_{i=1}^n \ell^2 = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n (Y_i - \hat{b}_0 - \hat{b}_1 X_{1i} - \hat{b}_2 X_{2i})^2$$

من أجل الحصول على المعادلات الطبيعية الثلاث يجب أن نجري

عملية التفاضل الجزئي للدالة بالنسبة إلى \hat{b}_0 و \hat{b}_1 و \hat{b}_2 :

أولاً - المشتقة الجزئية لـ \hat{b}_0 :

$$\begin{aligned}\frac{\partial \sum \ell_i^2}{\partial \hat{b}_0} &= \frac{\partial \sum (Y_i - \hat{b}_0 - \hat{b}_1 X_{1i} - \hat{b}_2 X_{2i})^2}{\partial \hat{b}_0} = 0 \\ &= -2 \sum (Y_i - \hat{b}_0 - \hat{b}_1 X_{1i} - \hat{b}_2 X_{2i}) = 0 \\ &= \sum Y_i - \sum \hat{b}_0 - \sum \hat{b}_1 X_{1i} - \sum \hat{b}_2 X_{2i} = 0 \\ \sum Y_i &= n\hat{b}_0 + \hat{b}_1 \sum X_{1i} + \hat{b}_2 \sum X_{2i} \dots\dots\dots (1)\end{aligned}$$

ثانياً - المشتقة الجزئية لـ \hat{b}_1 :

$$\begin{aligned}\frac{\partial \sum \ell_i^2}{\partial \hat{b}_1} &= \frac{\partial \sum (Y_i - \hat{b}_0 - \hat{b}_1 X_{1i} - \hat{b}_2 X_{2i})^2}{\partial \hat{b}_1} = 0 \\ &= -2 \sum X_{1i} (Y_i - \hat{b}_0 - \hat{b}_1 X_{1i} - \hat{b}_2 X_{2i}) = 0 \\ \sum X_{1i} Y_i - \sum \hat{b}_0 X_{1i} - \sum \hat{b}_1 X_{1i}^2 - \sum \hat{b}_2 X_{1i} X_{2i} &= 0 \\ \sum X_{1i} Y_i &= \hat{b}_0 \sum X_{1i} + \hat{b}_1 \sum X_{1i}^2 + \hat{b}_2 \sum X_{1i} X_{2i} \dots\dots\dots (2)\end{aligned}$$

ثالثاً - المشتقة الجزئية لـ \hat{b}_2 .

$$\begin{aligned}\frac{\partial \sum \ell_i^2}{\partial \hat{b}_2} &= \frac{\partial \sum (Y_i - \hat{b}_0 - \hat{b}_1 X_{1i} - \hat{b}_2 X_{2i})^2}{\partial \hat{b}_2} = 0 \\ &= -2 \sum X_{2i} (Y_i - \hat{b}_0 - \hat{b}_1 X_{1i} - \hat{b}_2 X_{2i}) = 0 \\ \sum X_{2i} Y_i - \sum \hat{b}_0 X_{2i} - \sum \hat{b}_1 X_{1i} X_{2i} - \sum \hat{b}_2 X_{2i}^2 &= 0 \\ \sum X_{2i} Y_i &= \hat{b}_0 \sum X_{2i} + \hat{b}_1 \sum X_{1i} X_{2i} + \hat{b}_2 \sum X_{2i}^2 \dots\dots (3)\end{aligned}$$

إن المعادلات (1)(2)(3) هي المعادلات الثلاثة الطبيعية أو الإعتيادية لطريقة المربعات الصغرى .

لدينا القوانين التي يعبر فيها عن المتغيرات بإنحرافاتاها عن وسطها الحسابي ، والتي من الممكن أيضاً إستخدامها لإيجاد تقديرات المعاملات b_0 و b_1 و b_2 :

$$\hat{b}_1 = \frac{\left[\sum (x_{li} - \bar{x}_1)(y_i - \bar{y}) \sum (x_{2i} - \bar{x}_2)^2 \right] - \left[\sum (x_{2i} - \bar{x}_2)(y_i - \bar{y}) \sum (x_{li} - \bar{x}_1)(x_{2i} - \bar{x}_2) \right]}{(\sum x_{li} - \bar{x}_1)^2 (\sum x_{2i} - \bar{x}_2)^2 - (\sum (x_{li} - \bar{x}_1)(x_{2i} - \bar{x}_2))}$$

$$\hat{b}_2 = \frac{\left[\sum (x_{2i} - \bar{x}_2)(y_i - \bar{y}) \sum (x_{li} - \bar{x}_1)^2 \right] - \left[\sum (x_{li} - \bar{x}_1)(y_i - \bar{y}) \sum (x_{li} - \bar{x}_1)(x_{2i} - \bar{x}_2) \right]}{(\sum x_{li} - \bar{x}_1)^2 (\sum x_{2i} - \bar{x}_2)^2 - (\sum (x_{li} - \bar{x}_1)(x_{2i} - \bar{x}_2))}$$

$$\hat{b}_0 = \bar{y} - \hat{b}_1 \bar{x}_1 - \hat{b}_2 \bar{x}_2$$

2-1-6 معامل التحديد أو التقرير

Coefficient of Multiple Determination of Multiple $R^2_{y \cdot x_1 x_2}$ Coefficient Correlation

عندما يكون لدينا أكثر من متغير توضيحي في الدالة فإننا نأخذ الإرتباط المتعدد ، إن مربع معامل الإرتباط يدعى معامل التحديد المتعدد ، أو مربع معامل الإرتباط المتعدد ، إن معامل التحديد أو التقرير المتعدد يرمز له بالحرف الكبير (R^2) مع إشارة الى المتغيرات التي نقوم بدراستها ، مثلاً في نموذج ذو ثلاث متغيرات فإن مربع معامل الإرتباط المتعدد هو ($R^2_{y \cdot x_1 x_2}$) . وكما في حالة نموذج المتغيرين فإن (R^2) يبين أو يوضح النسبة المئوية للانحراف الكلي الحاصلة في المتغير المعتمد (Y) الموضحة أو التي توضحها المساحة المستوية

للإنحدار (Regression Plane) أي بوساطة التغيرات الحاصلة في المتغير (X_1) والمتغير (X_2) :

$$R^2_{y \cdot x_1 x_2} = \frac{\hat{b}_1 \sum (Y_i - \bar{Y})(X_{1i} - \bar{X}_1) + \hat{b}_2 \sum (Y_i - \bar{Y})(X_{2i} - \bar{X}_2)}{\sum (Y_i - \bar{Y})^2}$$

إن قيمة (R^2) تقع بين 0 و 1 فكلما كانت قيمة (R^2) عالية فإن نسبة كبيرة من الانحرافات في (Y) توضح بوساطة المساحة المستوية للإنحدار ، أي أن التوفيق جيد للمساحة المستوية لمشاهدات العينة الإحصائية ، وكلما كانت قيمة (R^2) أقرب الى الصفر فإن التوفيق أو حسن التطابق يكون رديئاً .

3-1-6 تبين المعلمات \hat{b}_0 و \hat{b}_1 و \hat{b}_2 المقدرة

The Variance of the parameters

يمكن حساب تبين المعلمات المقدرة كما يأتي :

$$\text{Var}(\hat{b}_0) = \delta_u^2 \left[\frac{1}{n} + \frac{\bar{X}_1^2 \sum (X_2 - \bar{X}_2)^2 + \bar{X}_2^2 \sum (X_1 - \bar{X}_1)^2 - 2\bar{X}_1 \bar{X}_2 \sum (X_1 - \bar{X}_1)(X_2 - \bar{X}_2)}{\sum (X_1 - \bar{X}_1)^2 \sum (X_2 - \bar{X}_2)^2 - (\sum (X_1 - \bar{X}_1)(X_2 - \bar{X}_2))^2} \right]$$

$$\text{Var}(\hat{b}_1) = \delta_u^2 \left[\frac{\sum (X_2 - \bar{X}_2)^2}{\sum (X_1 - \bar{X}_1)^2 \sum (X_2 - \bar{X}_2)^2 - (\sum (X_1 - \bar{X}_1)(X_2 - \bar{X}_2))^2} \right]$$

$$\text{Var}(\hat{b}_2) = \delta_u^2 \left[\frac{\sum (X_1 - \bar{X}_1)^2}{\sum (X_1 - \bar{X}_1)^2 \sum (X_2 - \bar{X}_2)^2 - (\sum (X_1 - \bar{X}_1)(X_2 - \bar{X}_2))^2} \right]$$

عندما يكون :

$$\hat{\delta}_u^2 = \frac{\sum \ell_i^2}{n - k}$$

حيث أن (k) ترمز الى عدد المعلمات المقدرة ، ففي حالة النموذج ذو الثلاث متغيرات تكون $(3=R)$ ، أما (n) فهي عدد المشاهدات في العينة قيد الدراسة .

مثال : الجدول (1-6) يحتوي مشاهدات عن الكمية المطلوبة من سلعة معينة (Y) وسعر تلك السلعة (X_1) ودخل المستهلك (X_2) ، قدر دالة الإنحدار لهذه العلاقة :

جدول (1-6)

n	$\sum_{i=1}^n Y_i$	$\sum_{i=1}^n X_{1i}$	$\sum_{i=1}^n X_{2i}$	$\sum_{i=1}^n (Y_i - \bar{Y})$	$\sum_{i=1}^n (X_{1i} - \bar{X}_1)$	$\sum_{i=1}^n (X_{2i} - \bar{X}_2)$	$\sum_{i=1}^n (Y_i - \bar{Y})^2$	$\sum_{i=1}^n (X_{1i} - \bar{X}_1)^2$	$\sum_{i=1}^n (X_{2i} - \bar{X}_2)^2$	$\sum_{i=1}^n (Y_i - \bar{Y})(X_{1i} - \bar{X}_1)$	$\sum_{i=1}^n (Y_i - \bar{Y})(X_{2i} - \bar{X}_2)$	$\sum_{i=1}^n (X_{1i} - \bar{X}_1)(X_{2i} - \bar{X}_2)$
1	100	5	1000	20	-1	200	400	1	40000	-20	4000	-200
2	75	7	600	-5	1	-200	25	1	40000	-5	1000	-200
3	80	6	1200	0	0	400	0	0	160000	0	0	0
4	70	6	500	-10	0	-300	100	0	90000	0	3000	0
5	50	8	300	-30	2	-500	900	4	250000	-60	15000	-1000
6	65	7	400	-15	1	-400	225	1	160000	-15	6000	-400
7	90	5	1300	10	-1	500	100	1	250000	-10	5000	-500
8	100	4	1100	20	-2	300	400	4	90000	-40	6000	-600
9	110	3	1300	30	-3	500	900	9	250000	-90	15000	-1500
10	60	9	300	-20	3	-500	400	9	250000	-60	10000	-1500
N=10	$\sum Y_i = 800$	$\sum X_{1i} = 60$	$\sum X_{2i} = 8000$	$\sum (Y_i - \bar{Y}) = 0$	$\sum (X_{1i} - \bar{X}_1) = 0$	$\sum (X_{2i} - \bar{X}_2) = 0$	$\sum (Y_i - \bar{Y})^2 = 3450$	$\sum (X_{1i} - \bar{X}_1)^2 = 30$	$\sum (X_{2i} - \bar{X}_2)^2 = 1580000$	$\sum (X_{1i} - \bar{X}_1)(X_{2i} - \bar{X}_2) = -300$	$\sum (Y_i - \bar{Y})(X_{2i} - \bar{X}_2) = 65000$	$\sum (X_{1i} - \bar{X}_1)(X_{2i} - \bar{X}_2) = -5900$

$$800 = \bar{X}_2$$

$$6 = \bar{X}_1$$

$$80 = \bar{Y}_1$$

الآن نقوم بما يأتي :

1- نعوض في قانون إيجاد معاملات الإنحدار \hat{b}_1 و \hat{b}_2 :

$$\hat{b}_1 = \frac{(-300)(1580000) - (65000)(-5900)}{(30)(1580000) - (-5900)^2} = \frac{-90500}{12590} = -7.19$$

$$b_2 = \frac{(65000)(30) - (-300)(-5900)}{(30)(1580000) - (-5900)} = \frac{180}{12590} = 0.0143$$

لذلك :

$$\hat{b}_0 = \bar{Y} - \hat{b}_1 \bar{X}_1 - \hat{b}_2 \bar{X}_2$$

$$= 80 - (-7.19)(6) - (0.0143)(800) = 111.69$$

2- معامل التحديد أو التقرير المتعدد (R^2) يمكن حسابه على النحو الآتي :

$$R^2 = \frac{\hat{b}_1 \sum (Y_i - \bar{Y})(X_{1i} - \bar{X}_1) + (\hat{b}_2 \sum (Y_i - \bar{Y})(X_{2i} - \bar{X}_2))}{\sum (Y_i - \bar{Y})^2}$$

$$= \frac{(-7.19)(-300) + (0.0143)(65000)}{3450} = 0.894$$

3- لتقدير الخطأ المعياري (The Standard Error) لكل من \hat{b}_1 و \hat{b}_2 :

هنا نحن بحاجة الى تقدير الخطأ المعياري للمتغير العشوائي للمجتمع

الإحصائي (δ_u^2) . إن الصيغة :

$$\hat{\delta}_u^2 = \frac{\sum \ell_i^2}{n - k}$$

تحتوي على مجموع تربيع البواقي أو الإنحرافات والتي يمكن الحصول

عليها من الصيغة الآتية :

$$R^2 = 1 - \frac{\sum \ell^2}{\sum (Y_i - \bar{Y})^2}$$

نقوم بالحل للحصول على ($\sum \ell^2$) نجد :

$$\sum \ell^2 = \sum (Y_i - \bar{Y})^2 (1 - R^2)$$

نعوض كل من ($\sum (Y_i - \bar{Y})^2$) و (R^2) نجد ($\sum \ell^2$) :

$$\sum \ell^2 = (3450)(0.106) = 365.7$$

لذلك :

$$\delta_u^2 = \frac{365.7}{10 - 3} = 52.24$$

4- إن تبين المعلمات \hat{b}_1 و \hat{b}_2 يمكن الحصول عليه عن طريق التعويض بالقانون الآتي :

$$\text{Var}(\hat{b}_1) = \delta_u^2 \left[\frac{\sum (X_{2i} - \bar{X}_2)^2}{\sum (X_{1i} - \bar{X}_1)^2 \sum (X_{2i} - \bar{X}_2)^2 - (\sum (X_{1i} - \bar{X}_1)(X_{2i} - \bar{X}_2))^2} \right]$$

$$\text{Var}(\hat{b}_1) = 52.24 \frac{1580000}{12590000} \approx 6.53$$

$$\text{Var}(\hat{b}_2) = \delta_u^2 \left[\frac{\sum (X_1 - \bar{X}_1)^2}{\sum (X_1 - \bar{X}_1)^2 \sum (X_2 - \bar{X}_2)^2 - (\sum (X_1 - \bar{X}_1)(X_2 - \bar{X}_2))^2} \right]$$

$$\text{Var}(\hat{b}_2) = 52.24 \frac{30}{12590000} = 0.0001$$

$$\text{Var}(\hat{b}_0) = \delta_u^2 \left[\frac{1}{n} + \frac{\bar{X}_1^2 \sum (X_2 - \bar{X}_2)^2 + \bar{X}_2^2 \sum (X_1 - \bar{X}_1)^2 - 2\bar{X}_1 \bar{X}_2 \sum (X_1 - \bar{X}_1)(X_2 - \bar{X}_2)}{\sum (X_1 - \bar{X}_1)^2 \sum (X_2 - \bar{X}_2)^2 - (\sum (X_1 - \bar{X}_1)(X_2 - \bar{X}_2))^2} \right]$$

$$\text{Var}(\hat{b}_0) = 553.69$$

ولذلك فإن الخطأ المعياري المقدّر للمعلمات سيكون بالشكل الآتي :

$$\delta(\hat{b}_1) = 2.55 \quad \delta(\hat{b}_2) = 0.01 \quad \delta(\hat{b}_0) = 23.5$$

5- نتائج الإنحدار ربما تعرض الآن على نحو مختصر كما يأتي :

$$\hat{Y} = 111.7 - 7.19X_1 + 0.014X_2$$

$$\delta_{(bi)} \quad (23.5) \quad (2.55) \quad (0.01) \quad R^2 = 0.894$$

$$t^* \quad (4.75) \quad (-2.8) \quad (1.28) \quad t_{0.025} = 2.365$$

إن المتغيرين (X_1, X_2) يوضحان 89% من الإنحراف الكلي في (Y) ،
أما تقديرات المعلمات $(\hat{b}_1 \hat{b}_0)$ هي ذات معنوية عالية إحصائياً ولكن تقدير
 (\hat{b}_2) هي معلمة ذات معنوية غير عالية في مستوى معنوية 5% .

2-6 نموذج العلاقات غير الخطية في الإنحدار

Nonlinear Relationships in Regression

إن العلاقة الخطية بين (Y) والمتغيرات التوضيحية (X_s) التي
إفترضناها سابقاً، ربما لا تكون مناسبة لعدد من العلاقات الإقتصادية ، في
الحقيقة إن العلاقة غير الخطية ربما نتوقعها في معظم العلاقات الإقتصادية اذا
ما عرفنا ان عالم الواقع الحقيقي معقد جداً .
بعض الأشكال المعروفة للعلاقات الإقتصادية غير الخطية يمكن أن
تعرض بالشكل الآتي مثلاً :

$$Y = b_0 + b_1X_1 + b_2X_1^2 + b_3X_1^3 + \dots + U$$

أو بوساطة دوال مع مرونة ثابتة مثلاً :

$$Y = b_0X_1^{b_1}X_2^{b_2}u$$

عندما يكون : b_1 = مرونة ثابتة لـ Y بالنسبة لـ X_1

b_2 = مرونة ثابتة لـ Y بالنسبة لـ X_2

البرهان : بالتعريف فإن المرونة هي :

$$n_{Y X_1} = \frac{dY}{dX_1} \cdot \frac{X_1}{Y}$$

مشتقة الدالة (Y) بالنسبة للمتغير (X_1) نعطينا :

$$\begin{aligned} \frac{\partial Y}{\partial X_1} &= b_1(b_0X_1^{b_1-1}X_2^{b_2}u) = b_1(b_0X_1^{b_1-1}X_2^{b_2}u)X_1^{-1} \\ &= b_1 \frac{Y}{X_1} \end{aligned}$$

نعوض عن $\frac{dY}{dX_1}$ بالقيمة الآتية $(b \frac{Y}{X_1})$ في قانون المرونة :

$$n_{Y X_1} = b \frac{Y}{X_1} \cdot \frac{X_1}{Y} = b_1$$

وهكذا فإن (b_1) هي المرونة الثابتة لـ (Y) بالنسبة للمتغير (X_1) ، مثلاً
في النظرية الإقتصادية الجزئية ، شكل منحنيات معدل الكلفة يأخذ شكل حرف (U) يمكن أن يوضع تقريباً بصيغة دالة غير خطية :

$$C = b_0 + b_1X - b_2X^2 + b_3X^3 + U$$

عندما يكون $C =$ الكلفة و $X =$ الإنتاج .

في هذه الحالة معدل الكلفة الكلية هو :

$$\frac{C}{X} = \frac{b_0}{X} + b_1 - b_2X + b_3X^2$$

وهذه الدالة ذات شكل حرف U .

وبالطريقة نفسها فإن دالة الطلب مع مرونة سعرية ثابتة ومرونة دخلية

ثابتة يمكن أن يعبر عنها بالمعادلة الآتية :

$$Q_x = b_0 p_x^{b_1} Y_u^{b_2}$$

عندما يكون : $Q_x =$ الطلب على السلعة X .

$P_x =$ سعر السلعة X .

$Y =$ الدخل تحت التصرف للمستهلكين .

مرونة الطلب السعرية $\frac{dQ}{dP} \cdot \frac{P}{Q} = n_P = b_1$.

المرونة الدخلية للطلب $\frac{dQ}{dY} \cdot \frac{Y}{Q} = n_Y = b_2$.

6-3 تحويل الدوال غير الخطية التي تحتوي مرونيات ثابتة الى دوال خطية .

إذا كانت العلاقة من نوع العلاقة الثابتة المرونة

$$Y = b_0 X_1^{b_1} X_2^{b_2}$$

إن الخطأ المعياري (المتغير العشوائي) في هذه الحالة يضرب بقيم المتغيرات التوضيحية ، ولذلك لا نستطيع أن نضع الافتراض الذي يقول أن $E(u)=0$ وذلك لأنه إذا افترضنا هذا الافتراض فإن الدالة ستختفي ، بدلاً من ذلك نكتب العلاقة التي تحتوي على مرونيات ثابتة على نحو ملائم آخر :

$$Y = b_0 X_1^{b_1} X_2^{b_2} e^u$$

عندما يكون $e \approx 2.718$ أساس اللوغاريتم الطبيعي ، إن أفضل تحويل لتقديرات صيغة المرونة الثابتة هو العمل مع لوغاريتمات (Logarithms) المتغيرات (الى أساس اللوغاريتم e) بهذه الصيغة :

$$\log_e Y = \log_e b_0 + b_1 \log_e X_1 + b_2 \log_e X_2 + u$$

بعد ذلك نعطي قيمة :

$$\log_e X_2 = X_2^* , \log_e X_1 = X_1^* , \log_e Y = Y^*$$

وبهذا يكون بإمكاننا أن نطبق طريقة المربعات الصغرى الإعتيادية

(OLS) للدالة المحولة الى العلاقة الخطية :

$$Y^* = b_0^* + b_1 X_1^* + b_2 X_2^* + u$$

مثال :

الجدول (6-2) الآتي يعرض الطلب (Y) على السلعة (X) وسعرها (X_1) بوحدات لأي عملة ، ونحن نرغب بتقدير دالة الطلب :

جدول (2-6) الطلب على السلعة (X) مع سعرها

الملاحظات	Y الكمية المطلوبة	X ₁ السعر	log _e Y	LogX ₁
	Y*	X ₁ *		
1	543	61	6.2971	4.1109
2	580	54	6.3631	3.9890
3	618	50	6.4265	3.9120
4	695	43	6.5439	3.7612
5	724	38	6.5848	3.6376
6	812	36	6.6995	3.5835
7	887	28	6.7879	3.3322
8	991	23	6.8987	3.1355
9	1186	19	7.0685	2.9445
10	1940	10	7.5705	2.3026

ونحن نرغب في تقدير دالة الطلب الآتية :

$$Y = b_0 X_1^{b_1} e^u$$

نقوم بأخذ لوغاريتم المتغيرات (الى أساس اللوغاريتم الطبيعي e) وبعد

ذلك نستخدم طريقة المربعات الصغرى الإعتيادية (OLS) في الإنحدار الخطي

$$\text{Log}_e Y = \text{log}_e b_0 + b_1 \text{log}_e X_1$$

إن البيانات الملاءمة موجودة في الجدول (2-6) ، دالة الطلب المقدرة

هي :

$$\text{log}_e Y = 9.121 - 0.69 \text{log}_e X \quad R^2 = 0.992$$

$$\hat{Y} = A \cdot P^{-0.69}$$

$$(9.121 = \hat{b}_0 = \text{مقلوب اللوغاريتم})$$

إن مرونة الطلب السعرية هي -0.69 وهذا يعني أن الطلب على السلعة

(X) هو طلب غير مرن مع السعر .

الفصل السابع

الإختبارات الإحصائية لمعنوية المعلمات المقدرة بطريقة المربعات الصغرى الإعتيادية

الفصل السابع

الإختبارات الإحصائية لمعنوية
المعلمات المقدرة بطريقة المربعات
الصغرى الإعتيادية

الفصل السابع

الإختبارات الإحصائية لمعنوية المَعْلَمَاتِ المقدرة بطريقة المربعات الصغرى الإعتيادية

الفصل السابع

الإختبارات الإحصائية لمعنوية المعلمات المقدرة بطريقة المربعات الصغرى الإعتيادية

الإختبارات الإحصائية لمعنوية المعلمات المقدرة بطريقة المربعات الصغرى الإعتيادية

1-7 مقدمة

في الفصول السابقة تم بناء النموذج والقوانين اللازمة لتقدير معلمات العلاقات الإقتصادية بإستخدام طريقة المربعات الصغرى الإعتيادية ، والخطوة التي تلي عملية تقدير المعلمات هي الخطوة المتعلقة ببناء معيار للحكم على جودة المعلمات المقدرة ، ثمة ثلاثة معايير لهذا الغرض :

أولاً - المعيار النظري المسبق : وهذا المعيار يوضح من قبل النظرية الإقتصادية ، ويشير الى إشارة وحجوم المعلمات ، فضلاً عن أن هذا المعيار النظري يحدد في المرحلة الأولى من الدراسة الإقتصادية القياسية وهي مرحلة تحديد النموذج .

ثانياً - المعيار الإحصائي : وهذا المعيار يوضح من قبل نظرية الإحصاء ويتضمن عدداً من الإختبارات الإحصائية لإختبار معنوية المعلمات المقدرة ، وسيتم التركيز على دراسة هذا المعيار في هذا الفصل .

ثالثاً - المعيار الإقتصادي القياسي : وهذا المعيار يعتمد على نظرية الإقتصاد القياسي .

إن أهم الإختبارات الإحصائية والأكثر إستعمالاً في الإقتصاد القياسي وهما إختبارين أساسيين :

الإختبار الأول : وهو مربع معامل الارتباط (r^2) الذي يستخدم للحكم على القابلية التوضيحية للإنحدار الخطي بين المتغير المعتمد (Y) والمتغير التوضيحي (X) .

الإختبار الثاني : يعتمد على الأخطاء المعيارية (Standard Errors) للمعلمات المقدرة ، ويطبق في حالة درجة الحكم على الإعتماد الإحصائي على المعلمات

الفصل السابع

الإختبارات الإحصائية لمعنوية المعلمات المقدرة بطريقة المربعات الصغرى الإعتيادية

المقدرة \hat{b}_0 و \hat{b}_1 ، إن هذا الإختبار يعطينا مقياس لدرجة الثقة التي يمكن أن نعزيبها أو نعطيها لتقديرات \hat{b}_0 و \hat{b}_1 ، كما أن هذا الإختبار يمكن الباحث أن يقرر جودة التقديرات للتعبير عن المعلمات الحقيقية للمجتمع الإحصائي (b_1, b_0) .

2-7 إختبار جودة توفيق خط الإنحدار باستخدام مربع معامل الارتباط (r^2) .

بعد تقدير المعلمات (Parameters) وتحديد خط الإنحدار للمربعات الصغرى ، نكون بحاجة الى التعرف أو أن نعرف مدى جودة توفيق خط الإنحدار لملاحظات العينة الإحصائية من (Y) و (X) وهذا يعني أننا بحاجة الى أن نقيس إنتشار أو تشتت الملاحظات (dispersion of observations) حول خط الإنحدار ، إن معرفة هذه الحالة يعد ضرورياً وأساسياً ، وذلك لأنه كلما كانت الملاحظات قريبة من خط الإنحدار كلما كان ذلك الخط جيد التوفيق وهذا يعني أن خط الإنحدار يوضح على نحو أفضل من الانحرافات في المتغير المعتمد (Y) بسبب التغيرات الحاصلة في المتغير التوضيحي أو المتغيرات التوضيحية .

إن مقياس توفيق جودة خط الإنحدار هو (r^2) الذي يبين النسبة المئوية للانحراف الكلي (Total Variation) في المتغير المعتمد الذي يمكن توضيحه بوساطة المتغير التوضيحي (X) .

نقوم برسم الملاحظات في شكل الإنتشار و ثم نحسب الوسط الحسابي

للمتغير التوضيحي والوسط الحسابي للمتغير المعتمد .

$$\bar{Y} = \frac{\sum Y_i}{n} \quad \bar{X} = \frac{\sum X_i}{n}$$

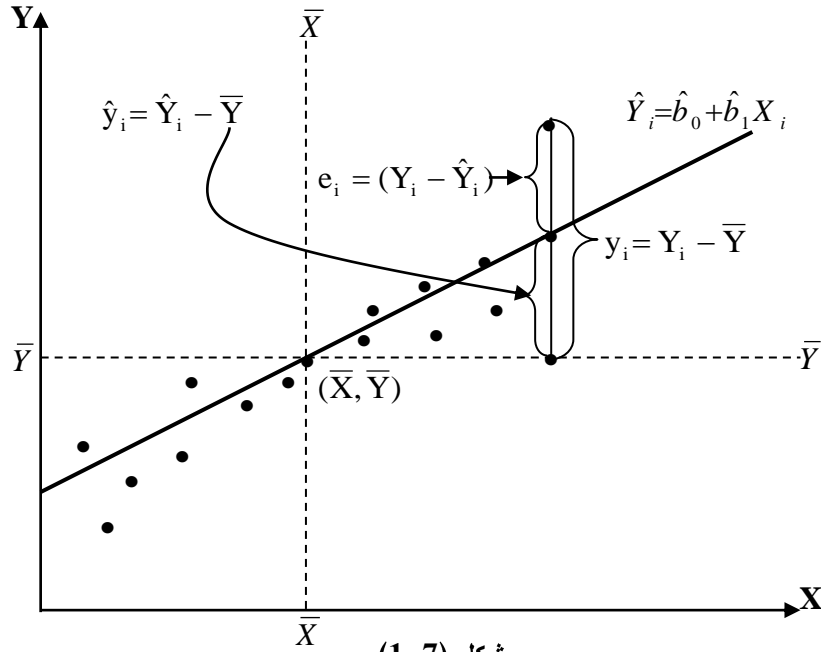
الفصل السابع

الإختبارات الإحصائية لمعنوية المعلومات المقدرة بطريقة المربعات الصغرى الإعتيادية

في الشكل (1-7) تبدو نقاط المشاهدات مع رسم الأعمدة
(perpendiculars) التي تمر عبر نقطة الوسط الحسابي لـ (X) والوسط
الحسابي لـ (Y) .

الفصل السابع

الإختبارات الإحصائية لمعنوية المعلمات المقدرة بطريقة المربعات الصغرى الإعتيادية



عند توفيق خط الانحدار ($\hat{Y}_i = \hat{b}_0 + \hat{b}_1 X_i$) نحاول أن نحصل على توضيح للانحرافات الحاصلة في المتغير المعتمد (Y) التي تنتجها أو تسببها التغيرات في المتغير التوضيحي (X) ، وفي الحقيقة إن المشاهدات المنحرفة عن خط الانحدار المقدر تبين أن خط الانحدار يوضح جزءاً من الانحراف الكلي في المتغير المعتمد فقط ، فهناك جزء من انحراف يعبر عنه بالشكل الآتي :

$$e_i = Y_i - \hat{Y}_i$$

يبقى بدون توضيح .

1- ربما يكون بإمكاننا أن نحسب الانحراف الكلي للمتغير المعتمد (Y) عن طريق مقارنة كل قيمة لـ (Y) مع قيمة الوسط الحسابي لـ (Y) التي هي (\bar{Y}) ونضيف كل النتائج للانحرافات ، نرسم للانحرافات في قيمة (Y_i) عن الوسط الحسابي بالحرف الصغير (y) لذلك يكون لدينا :

الفصل السابع

الإختبارات الإحصائية لمعنوية المعلومات المقدرة بطريقة المربعات الصغرى الإعتيادية

$$\sum_{i=1}^n y_i^2 = \sum_{i=1}^n (Y_i - \bar{Y})^2 \quad \text{الإنحراف الكلي في قيم (Y)}$$

يجب أن نلاحظ أنه من أجل الحصول على الإنحراف الكلي في قيم (Y) يجب علينا أن نربع الإنحرافات عن الوسط الحسابي ، وذلك لأن مجموع الإنحرافات البسيطة عن الوسط الحسابي لأي متغير تساوي صفراً ، وكما يأتي:

$$\sum_{i=1}^n (Y_i - \bar{Y}) = \sum_{i=1}^n y_i = 0$$

2- بالطريقة نفسها تعرف الإنحرافات للقيم المقدرة من خط الانحدار

(\hat{Y}) عن الوسط الحسابي ($(\hat{y}_i = \hat{Y}_i - \bar{Y})$) ، إن هذا الجزء من الإنحراف الكلي لقيم (Y_i) التي يوضحها خط . وهكذا فإن مجموع تربيع هذه الإنحرافات هو مجموع الإنحرافات في المتغير المعتمد التي يوضحها خط الانحدار .

$$\sum_{i=1}^n \hat{y}_i^2 = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2$$

3- عرفنا الإنحراف في القيم الفعلية عن القيم المقدرة بالقيمة

($e_i = Y_i - \hat{Y}_i$) وهو الجزء من الإنحرافات في المتغير المعتمد التي لا يوضحها خط الانحدار والتي تعزى الى الإضطراب الذي يسببه المتغير العشوائي (U) ، وهكذا فإن مجموع تربيع هذه الإنحرافات يعطينا مجموع الإنحراف في المتغير المعتمد (Y) الذي لا يوضحه خط الانحدار ، أي مجموع تربيع الإنحراف غير الموضح

$$\sum_{i=1}^n e_i^2 = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad \text{الإنحراف غير الموضح}$$

وعلى نحو مختصر :

$e_i = Y_i - \hat{Y}_i$	إنحراف المشاهدات (Y_i) عن خط الانحدار
$y_i = \hat{Y}_i - \bar{Y}$	إنحراف المشاهدات (Y_i) عن وسطها الحسابي

الفصل السابع

الإختبارات الإحصائية لمعنوية المعلمات المقدرة بطريقة المربعات الصغرى الإعتيادية

إنحراف القيم المقدرة (Y_i) عن الوسط الحسابي $\hat{y}_i = \hat{Y}_i - \bar{Y}$

$$\sum y_i^2 = \sum y_i^2 + \sum \ell_i^2$$

$$\left(\begin{array}{c} \text{الإنحراف} \\ \text{الكلي} \end{array} \right) = \left(\begin{array}{c} \text{الإنحراف الذي يوضحه} \\ \text{خط الانحدار} \end{array} \right) + \left(\begin{array}{c} \text{الإنحراف غير الموضح} \\ \text{بوساطة خط الانحدار} \end{array} \right)$$

$$r^2 = \frac{\sum y_i^2}{\sum y_i^2} = \frac{\text{الإنحراف الموضح}}{\text{الإنحراف الكلي}}$$

(r^2) يقرر النسبة من الإنحرافات في المتغير المعتمد (Y) التي يوضحها الإنحراف في قيم المتغير التوضيحي (X) ، لهذا السبب فإن (r^2) في بعض الأحيان يدعى معامل التحديد أو التقرير (Coefficient of Determination). مثلاً إذا كان ($0.90=r^2_{YX}$) فإن هذا يعني إن خط الانحدار يعطينا توفيق جيد للبيانات المشاهدة وذلك لأن هذا الخط يوضح (90%) من الإنحراف الكلي في قيم المتغير المعتمد (Y) عن وسطها الحسابي ، أما نسبة (10%) المتبقية من الإنحراف الكلي في (Y) لا يوضحها خط الانحدار ، ولكنها تعزى الى العوامل الداخلة في المتغير العشوائي الذي يسبب الإضطراب (Disturbance) .

إن قيم معامل التحديد (r^2) يمكن أن تأخذ قيماً تقع بين الصفر والواحد ، بعبارة أخرى إن (r^2) يأخذ قيماً على النحو الآتي :

$$0 \leq r^2 \leq 1$$

كما أن هناك علاقة بين مربع معامل الارتباط الذي هو (r^2) وميل الدالة

أو ميل خط الانحدار المقدر يمكن إيجاده من خلال القانون الآتي :

$$r^2 = \hat{b}_1 \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sum (Y_i - \bar{Y})^2}$$

الفصل السابع

الإختبارات الإحصائية لمعنوية المعلمات المقدرة بطريقة المربعات الصغرى الإعتيادية

مثلاً : في مثالنا عن دالة العرض في فصل سابق قدرنا دالة العرض كما يأتي :

$$\hat{Y} = 33.75 + 3.25X_i$$

ومن البيانات وجدنا أن :

$$156 = \sum (X_i - \bar{X})(Y_i - \bar{Y})$$

$$894 = \sum (Y_i - \bar{Y})^2$$

وباستخدام القانون أعلاه لإيجاد (r^2) عن طريق (\hat{b}_1) التي هي (3.25)

المعطاة في الدالة المقدرة :

$$\begin{aligned} r^2 &= 3.25 \times \frac{156}{894} \\ &= 0.570 \end{aligned}$$

3-7 إختبار الخطأ المعياري للمعلمات المقدرة (\hat{b}_0 و \hat{b}_1) بطريقة المربعات

الصغرى الإعتيادية .

إن المعلمات المقدرة بطريقة المربعات الصغرى (\hat{b}_0 و \hat{b}_1) يمكن الحصول عليها من عينة إحصائية (Sample) عن المشاهدات لمتغير المعتمد (Y) والمتغير التوضيحي (X) ، ولما كانت الأخطاء في تقديرات العينة الإحصائية مسألة حتمية في كل المعلمات المقدرة أصبح من الضروري تطبيق إختبارات المعنوية الإحصائية من أجل قياس حجم الخطأ وتحديد درجة الثقة في مشروعية المعلمات المقدرة ، هناك إختبارات عدة لهذا الغرض ، في الفقرة الحالية من هذا الفصل سنقوم بدراسة واحداً من الإختبارات المهمة وهو "إختبار الخطأ المعياري" الذي يعد شائعاً في البحث الإقتصادي القياسي التطبيقي ، إن هذا الإختبار يساعدنا أن نقرر كون المعلمات المقدرة (\hat{b}_0 و \hat{b}_1) هي معلمات

الفصل السابع

الإختبارات الإحصائية لمعنوية المعلمات المقدرة بطريقة المربعات الصغرى الإعتيادية

مختلفة عن الصفر على نحو كبير ، وهذا يعني كون العينة الإحصائية التي تم من خلالها الحصول على تلك التقديرات للمعلمات قد جاءت من مجتمع إحصائي معلماته الحقيقية لا تساوي صفراً ، وعلى نحو منهجي نختبر الفرضيتين الآتيتين:

أولاً : فرضية العدم (Null Hypothesis)

$$H_0 : b_i = 0$$

ثانياً : الفرضية البديلة (Alternative Hypothesis)

$$H_1 : b_i \neq 0$$

يمكن أن يلخص إختبار الخطأ المعياري أو الإنحراف المعياري بالشكل

الآتي :

$$\delta(\hat{b}_1) = \sqrt{\frac{\sum \ell_i^2}{(n-2) \left[\sum (X_i - \bar{X})^2 \right]}}$$
$$\delta(\hat{b}_0) = \sqrt{\frac{\left(\sum \ell_i^2 \right) \sum X_i^2}{(n-2)n \sum (X_i - \bar{X})^2}}$$

بعد ذلك نقارن الإنحرافات المعيارية مع القيم الرقمية للمعلمات المقدرة

$(\hat{b}_1$ و $\hat{b}_0)$ ، فإذا كان الإنحراف المعياري هو أصغر من نصف القيمة الرقمية

للمعلمة المقدرة $(\delta(\hat{b}_1) < \frac{\hat{b}_1}{2})$ فإننا نخلص الى القول إن تلك التقديرات هي

إحصائياً ذات معنوية إحصائية ، وهذا يعني أننا نرفض فرضية العدم التي تنص

على أن المعلمات الحقيقية للمجتمع الإحصائي $(b_i=0)$ ، وهذا يساوي قبول

الفرضية البديلة التي تنص على أن المعلمات الحقيقية للمجتمع الإحصائي (b_i)

مختلفة عن الصفر ، من جانب آخر اذا كان الخطأ المعياري للمعلمات المقدرة

الفصل السابع

الإختبارات الإحصائية لمعنوية المعلمات المقدرة بطريقة المربعات الصغرى الإعتيادية

هو أكبر من نصف القيمة الرقمية $(\frac{\hat{b}_1}{2})$ والنتيجة هي أن المعلمات المقدرة ليست ذات معنوية إحصائية ، وهذا يعني أننا نقبل فرضية العدم التي تنص على ان المعلمة الحقيقية للمجتمع الإحصائي $(b_i=0)$.

ومن أجل تسهيل عملية المقارنة بين الأخطاء المعيارية للمعلمات المقدرة مع القيم الرقمية للمعلمات المقدرة ، فإنه من الملائم أن نضع الأخطاء المعيارية بين اقواس تحت المعلمات المقدرة التي تشير اليها تلك الأخطاء المعيارية .

مثال : الأخطاء المعيارية لمعلمات دالة العرض التي تم تقديرها في فصول سابقة هي كما يأتي :

$$\delta(\hat{b}_1) = \sqrt{\frac{\sum \ell_i^2}{(n-2) \left[\sum (X_i - \bar{X})^2 \right]}} = \sqrt{\frac{383.98}{(10)(48)}} \approx 0.9$$

$$\delta(\hat{b}_0) = \sqrt{\frac{\left(\sum \ell_i^2 \right) \sum X_i^2}{(n-2)n \sum (X_i - \bar{X})^2}} = \sqrt{\frac{(383.98)(1020)}{(120)(48)}} \approx 8.3$$

والآن يمكن أن تعرض النتائج للإنداد بصيغة دالة :

$$\hat{Y}_i = 33.75 + 3.25X_i$$

$$(8.3) \quad (0.9)$$

على هذا النحو يمكن إجراء إختبار سريع لمعنوية المعلمات المقدرة عن

طريق الفحص :

$$\delta(\hat{b}_1) < \frac{\hat{b}_1}{2} \quad \delta(\hat{b}_0) < \frac{\hat{b}_0}{2}$$

الفصل السابع

الإختبارات الإحصائية لمعنوية المعلمات المقدرة بطريقة المربعات الصغرى الإعتيادية

وهكذا فإن $(\hat{b}_0$ و \hat{b}_1) هما ذات معنوية إحصائية عالية ، أي أنهما مختلفان عن قيمة الصفر ، وهذا يعني أننا نرفض فرضية العدم ونقبل الفرضية البديلة .

4-7 إختبار (Z) للمعلمات المقدرة بطريقة المربعات الصغرى

إن هذا الإختبار يعتمد على التوزيع الطبيعي ، يطبق هذا الإختبار في الحالتين الآتيتين :

أ- إذا كان تباين المجتمع الإحصائي معروفاً .

ب- إذا كان تباين المجتمع الإحصائي غير معروف .

فضلاً عن ان العينة الإحصائية التي يتم بوساطتها الوصول الى تقديرات المعلمات للمجتمع الإحصائي هو حجم كبير ما فيه الكفايه ($n > 30$) أكثر من ثلاثين مشاهدة ، فإذا لم تكن هذه الشروط موجودة فإننا نلجأ الى تطبيق إختبار (t) الذي سوف نوضحه في الفقرة القادمة .

في تطبيقات الإقتصاد القياسي فإن تباين المجتمع الإحصائي لـ (Y) هو تباين (u) الذي هو (σ_u^2) وهو مجهول ، ولكن اذا كانت لدينا عينة إحصائية كبيرة ($n > 30$) فإننا نستطيع إستخدام التوزيع الطبيعي ونطبق إختبار (Z) على نحو تقريبي ، وذلك لأن التباين المقدر للعينة الإحصائية (σ^2) هو عبارة عن تقدير تقريبي لتباين المجتمع الإحصائي المجهول (σ_u^2) بالنسبة لعينة كبيرة الحجم .

إن إختبار (Z) ربما يوضح بالخطوات الآتية :

نريد أن نختبر أولاً فرضية العدم (Null Hypothesis)

$$H_0 : b_i = 0$$

مقابل أو ضد الفرضية البديلة (Alternative Hypothesis)

الفصل السابع

الإختبارات الإحصائية لمعنوية المعلمات المقدرة بطريقة المربعات الصغرى الإعتيادية

$$H_1 : b_i \neq 0$$

قلنا سابقاً أنه في ظل ظروف فرضيات معينة تتعلق بقيم المتغير (U) فإن (U) سيتبع نظام $[U \sim N(0, \delta_u^2)]$ ، أي أن المتغير (U) له وسط حسابي يساوي صفراً وإن له تباين هو (δ_u^2) فإن تقديرات المربعات الصغرى $(\hat{b}_1$ و $\hat{b}_0)$ لهما التوزيعات الإعتيادية الآتية :

$$\hat{b}_0 \sim N \left(b_0, \delta_{(\hat{b}_0)} = \sqrt{\delta_u^2 \frac{\sum X^2}{n \sum (X_i - \bar{X})^2}} \right)$$

$$\hat{b}_1 \sim N \left(b_1, \delta_{(\hat{b}_1)} = \sqrt{\delta_u^2 \frac{1}{n \sum (X_i - \bar{X})^2}} \right)$$

إن التوزيعات الطبيعية أعلاه يمكن أن يقاس عليها أو إعتمادها بوصفها معياراً ، أي يمكن تحويلها الى وحدات متغير معياري (Z) الذي يتميز بكون وسطه الحسابي يساوي صفراً وتباين $(Z \sim N(0,1))$ من خلال قانون التحويل :

$$Z_i = \frac{X_i - \mu}{\delta} \sim N(0,1)$$

عندما يكون :

(X_i) قيمة المتغير الذي نريد أن نجعله طبيعياً (أي تحويل قيمة المتغير (X) الى وحدات (Z) المعيارية) .

(μ) الوسط الحسابي لتوزيع المتغير .

(δ) الانحراف المعياري للمتغير .

في حالة توزيع تقديرات المربعات الصغرى $(\hat{b}_1$ و $\hat{b}_0)$ فإن قانون

التحويل أعلاه يأخذ الشكل الآتي :

الفصل السابع

الإختبارات الإحصائية لمعنوية المعلمات المقدرة بطريقة المربعات الصغرى الإعتيادية

$$Z = \frac{\hat{b}_0 - b_0}{\delta_{(\hat{b}_0)}} = \frac{\hat{b}_0 - b_0}{\sqrt{\frac{\delta_u^2 \sum X_i^2}{n \sum (X_i - \bar{X})^2}}} \sim N(0,1) \quad \text{بالنسبة الى } \hat{b}_0$$

$$Z = \frac{\hat{b}_1 - b_1}{\delta_{(\hat{b}_1)}} = \frac{\hat{b}_1 - b_1}{\sqrt{\frac{\delta_u^2}{\sum (X_i - \bar{X})^2}}} \sim N(0,1) \quad \text{بالنسبة الى } \hat{b}_1$$

باستخدام قوانين التحويل أعلاه نستطيع إجراء إختبار لأية فرضية تتعلق بالقيمة الحقيقية للمعلمة (\hat{b}_1) للمجتمع الإحصائي ، نفترض أننا نريد أن نختبر فرضية العدم التي تنص على أن القيمة الحقيقية للمعلمة (\hat{b}_1) هي مساوية الى قيمة معينة مثلاً (b_1^*) ، وهنا فإن غرضنا الأساسي هو إختبار فرضية العدم :

$$H_0 : b_1 = b_1^*$$

مقابل أو ضد الفرضية البديلة

$$H_1 : b_1 \neq b_1^*$$

نعوض عن (b_1) بقيمة (b_1^*) في القانون أعلاه ، ولدينا تقدير قيمة

(\hat{b}_1) والانحراف المعياري أو الخطأ المعياري للمعلمة (b_1) هو $(\delta_{(\hat{b}_1)})$

وبذلك نستطيع حساب قيمة (Z^*) :

$$Z^* = \frac{\hat{b}_1 - b_1^*}{\delta_{(\hat{b}_1)}}$$

بعد أن حصلنا على هذه القيم نستطيع حساب إحتمال الحصول على

تقدير لـ (b_1) اذا كانت فرضيتنا الأساسية $(b_1 = b_1^*)$ هي حقيقية نتبع الخطوات الآتية :

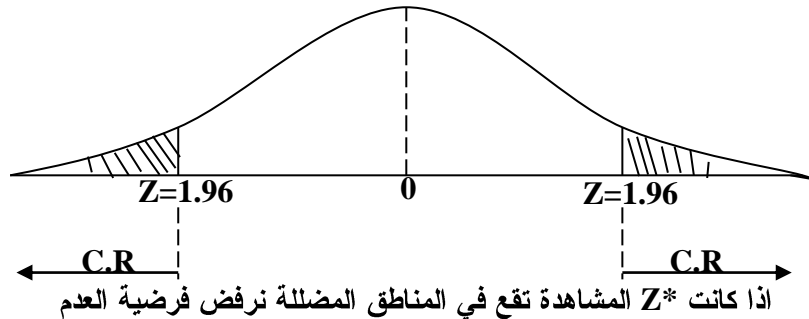
الفصل السابع

الإختبارات الإحصائية لمعنوية المعلمات المقدرة بطريقة المربعات الصغرى الإعتيادية

نختار مستوى من مستويات المعنوية من أجل أن نقرر قبول أو رفض الفرضية (إن مستوى المعنوية هو احتمال إتخاذ القرار الخطأ يعني احتمال رفض الفرضية عندما تكون فعلياً هي الصحيحة أو الحقيقية) .

عادة في البحث الإقتصادي القياسي نختار مستوى (5%) أو (1%) من المعنوية ، وهذا يعني أننا في حالة إتخاذنا قراراً نسمح لإحتمال (5%) أن يكون قرارنا خطأ أي قرار رفضنا للفرضية عندما تكون فعلياً هي الصحيحة ، وعادة في العمل الإقتصادي القياسي التطبيقي يستخدم إختبار ذو نهائيتين أو جانبيين (Two-Tail Test) ، إن إختيار إختبار الجانبيين يتضمن عدم وجود معرفة مسبقة تتعلق بإشارة المعلمة التي يراد إختبار معنويتها الإحصائية ، ولكن على كل حال فإن إختيار الجانب الواحد أو النهاية الواحدة (One-Tail Test) سيكون أكثر ملائمة في أغلبية التطبيقات الإقتصادية القياسية وذلك لأن النظرية الإقتصادية تقوم بإعطائنا معلومات أو توقعات مسبقة تتعلق بإشارة المعلمات للعلاقات الإقتصادية .

يجب أن نختار المنطقة الحرجة (Critical Region) ، بحيث أن إختيار كلا الجانبيين للتوزيع المعياري الطبيعي وبخاصة ذلك الجزء لكل جانب من الإختبار الذي يقابل نصف احتمال المعنوية ، مثلاً إذا إختارنا مستوى معنوية (5%) ، فإن كل جانب سيحتوي المنطقة أو الجزء من الإحتمال (0.025)(probability) ، كما في الشكل (2-7) :



شكل (2-7) إختبار ذو نهائيتين أو جانبيين مع 5% مستوى معنوية

الفصل السابع

الإختبارات الإحصائية لمعنوية المعلومات المقدرة بطريقة المربعات الصغرى الإعتيادية

من جدول التوزيع المعياري الطبيعي نستطيع أن نجد القيم الحرجة لـ (Z) التي تقابل الإحتمال (0.025) في كل نهاية من نهايات المنحنى .

(Z^*) والخطوة الأخيرة هي مقارنة قيمة (Z^*)

المشاهدة مع القيم الحرجة لـ (Z) .

فإذا كانت (Z^*) المشاهدة تقع ضمن المنطقة الحرجة أي أن

($Z^* < 1.96$ أو $1.96 < Z^*$) فإننا نرفض فرضية العدم التي تقول أن القيمة

الحقيقية لـ (b) هي (b^*) وذلك لأن إحتمال (Z^*) صغير جداً .

بعبارة أخرى ليس من المحتمل أن مثل (Z^*) يمكن ان تشاهد اذا كانت

الفرضية الأساسية (H_0) هي الحقيقية أو الصحيحة ، فإذا كان الوضع بالعكس

فإن قيمة (Z^*) للعينة يقع خارج المنطقة الحرجة المختارة ، وهذا يعني أن

($-1.96 < Z^* < 1.96$) فإننا نقبل فرضية العدم ($H_0 : b_1 = b_1^*$) وذلك لأن إحتمال

أن يكون (Z^*) اذا كانت فرضية العدم هي الحقيقية كبيراً .

مثال (1) : نفترض أن $\hat{b}_1 = 29.48$ و $\delta_{(\hat{b}_1)} = 36.0$

ونريد أن نختبر فرضية العدم (H_0)

$$H_0 : b_1^* = 25.0$$

من قانون التحويل لـ (Z) نحصل على :

$$Z^* = \frac{\hat{b}_1 - b_1^*}{\delta_{(\hat{b}_1)}} = \frac{29.48 - 25.0}{36.0} = 0.12$$

لأن (Z^*) لم تقع في المنطقة الحرجة ($Z^* < 1.96$) فإننا نقبل فرضية

العدم بأن ($b^* = 25.0$) وذلك لأن إحتمال المشاهدة لمثل هذه القيمة (Z^*)

(أكبر من 5%) .

الفصل السابع

الإختبارات الإحصائية لمعنوية المعلمات المقدرة بطريقة المربعات الصغرى الإعتيادية

ولكن في الإقتصاد القياسي التطبيقي أصبح معتاداً لإختبار الفرضية التي تقول أن المعلمة الحقيقية للمجتمع الإحصائي تساوي صفراً ، وهذا هو الشكل النموذجي لفرضية العدم في الإقتصاد القياسي وهي :

$$H_0 : b_i = 0$$

ويتم إختبار هذه الفرضية ضد أو مقابل الفرضية البديلة :

$$H_1 : b_i \neq 0$$

إن معنى ومتضمنات هذه الفرضية قد تم شرحه في الفقرة السابقة ولكن يمكن أن نلخص المناقشة كما يأتي :

إذا رفضنا فرضية العدم ، فإن المعلمة التجريبية (\hat{b}_1) هي ذات معنوية إحصائية عالية ، وهذا يعني أنها مختلفة عن الصفر على نحو كبير أو مهم . أما إذا قبلنا فرضية العدم فإن هذا يعني أن المعلمة (\hat{b}_1) هي ليست ذات معنوية إحصائية وأنه ربما لا تكون هناك علاقة خطية بين (X) و (Y) في المجتمع الإحصائي .

من أجل إجراء إختبار فرضية العدم أعلاه نجعل ($b=0$) في قانون التحويل الى قيم التوزيع الطبيعي في (Z) :

$$Z^* = \frac{\hat{b}_1 - b_1^*}{\delta(\hat{b}_1)} = \frac{\hat{b}_1 - 0}{\delta(\hat{b}_1)} = \frac{\hat{b}_1}{\delta(\hat{b}_1)}$$

وهكذا في حالة إختبار فرضية العدم ($H_0 : b_i = 0$) فإن أسلوب إختبار (Z) يختصر الى الخطوة البسيطة بتقسيم القيمة المقدرة للمعلمة (b_1) على الانحراف المعياري أو الخطأ المعياري لتلك القيمة وبعدها مقارنة (Z^*) الناتجة من التقسيم مع القيمة النظرية (الجدولية) لـ (Z) والتي تعطينا المنطقة الحرجة للإختبار ، القيمة النظرية لـ (Z) يمكن الحصول عليها من جدول التوزيع الطبيعي .

الفصل السابع

الإختبارات الإحصائية لمعنوية المعلمات المقدرة بطريقة المربعات الصغرى الإعتيادية

مثال (2) : نفترض أننا قدرنا دالة العرض من عينة إحصائية متكونة من (700) مشاهدة أي أن $n=700$ ، والدالة المقدرة كانت كما يأتي :

$$\hat{Y}_i = 100 + 4.00X_i$$

$$(1.5) \quad (20)$$

والآن سنجري إختبار (Z) للميل المقدر (b_1) ، الذي له خطأ معياري مساوياً الى (1.5) ، طالما أن العينة الإحصائية كبيرة الحجم ، فإن الانحراف المعياري المقدر للمعلمات هو تقريب جيد للانحراف الحقيقي لهذه المعلمات في المجتمع الإحصائي ، لذلك نستطيع تطبيق إختبار (Z) لإيجاد المعنوية الإحصائية لتقديرات (b_0 و b_1) :

فرضية العدم : $H_0 : b_1 = 0$

الفرضية البديلة : $H_1 : b_1 \neq 0$

الآن نحسب قيمة (Z^*) نجد أن :

$$Z^* = \frac{\hat{b}_1}{\delta(\hat{b}_1)} = \frac{4}{1.5} = 2.66$$

إن القيمة النظرية (الجدولية) لـ (Z) (عند مستوى 5% من المعنوية) هي 1.96 ، وهذا يعني ($Z < Z^*$) ولذلك نرفض فرضية العدم التي تقول أن ($b_1=0$) ، ونقبل الفرضية البديلة ، وهذا يعني أن الإنحدار المقدر ذا معنوية إحصائية عالية .

5-7 إختبار (t) للمعلمات المقدرة بطريقة المربعات الصغرى

إن هذا الإختبار مشابه لإختبار (Z) إلا إنه ملائم عندما يكون حجم العينة الإحصائية صغيراً (أقل من ثلاثين مشاهدة) ، ولإجراء إختبار (t) ذو النهايتين أو الجانبين نتبع الخطوات الآتية :

الفصل السابع

الإختبارات الإحصائية لمعنوية المعلمات المقدرة بطريقة المربعات الصغرى الإعتيادية

أ- نحدد فرضية العدم والفرضية البديلة .

ب- نختار مستوى المعنوية المرغوب (الدلالة) مثلاً 5% أو 1% .

ج- نحدد عدد درجات الحرية (Degree of Freedom) .

عندما تكون هذه المعلومات موجودة فمن الممكن أن نحدد المنطقة

الحرية (Critical Region) والتي تفصل بين مناطق الرفض ومناطق القبول،

أما القانون الذي بموجبه يمكن إيجاد قيمة (t) هو :

$$t^* = \frac{\hat{b}_i - b_1^*}{\sqrt{\hat{\delta}_{(\hat{b}_1)}^2}}$$

عندما يكون :

(\hat{b}_i) = تقدير (b_i) من المربعات الصغرى .

(b_i^*) = قيمة إفتراضية لـ (b_i) ($H_0 : b_i = b_1^*$) .

($\hat{\delta}_{(\hat{b}_1)}^2$) = التباين المقدّر لـ (b_i) من الانحدار .

(n) = حجم العينة الإحصائية .

(k) = العدد الكلي للمعلمات المقدرة .

عادةً في الإقتصاد القياسي يتم وضع أو بناء فرضية العدم أولاً :

$$H_0 : b_i = 0$$

ويتم إختيار هذه الفرضية ضد الفرضية البديلة :

$$H_1 : b_i \neq 0$$

في هذه الحالة فإن (t) يقلص الى ما يأتي :

$$t^* = \frac{\hat{b}_i}{\hat{\delta}_{(\hat{b}_1)}}$$

الفصل السابع

الإختبارات الإحصائية لمعنوية المعلمات المقدرة بطريقة المربعات الصغرى الإعتيادية

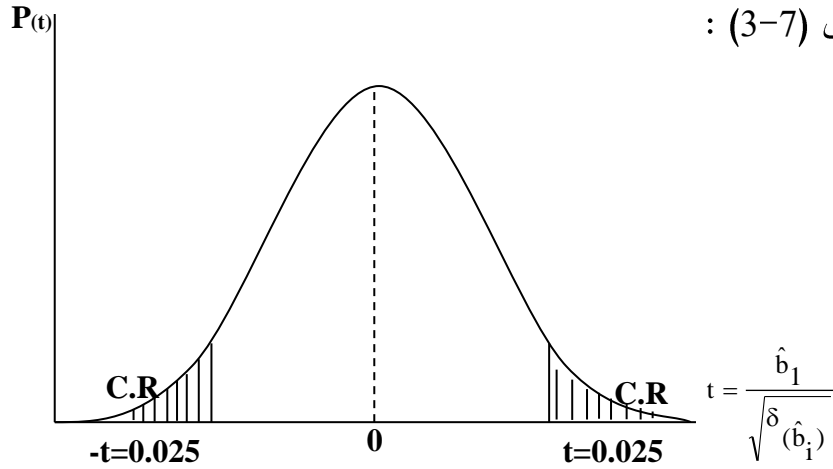
إن قيمة (t^*) للعينة تقدر بتقسيم القيمة المقدرة للمعلمة على الخطأ المعياري (Standard Error) ، وهذه القيمة تقارن مع القيمة النظرية أو الجدولية لـ (t) والتي عن طريقها تحدد المنطقة الحرجة في إختبار النهايتين أو الجانبين مع درجات حرية مساوية لـ $(n-k)$.

1- إذا وقعت (t^*) في المنطقة الحرجة فإننا نرفض فرضية العدم أي نقبل بأن تقدير (\hat{b}_i) هو ذا معنومية إحصائية عالية .

2- إذا وقعت (t^*) في منطقة القبول (acceptance region) عندئذ نقبل فرضية العدم بأن تقدير (\hat{b}_i) هو ليس ذا معنومية إحصائية عالية بمستوى معنوية 5% .

إن إختبار النهايتين لإختبار فرضية العدم $(H_0 : b_i = 0)$ موضحاً في

الشكل (3-7) :



شكل (3-7)

فإذا كانت قيمة (t) المشاهدة (t^*) تقع في المنطقة الحرجة (المنطقة المضللة) فيجب أن نرفض فرضية العدم عند مستوى معنوية (0.05) .

الفصل السابع

الإختبارات الإحصائية لمعنوية المعلمات المقدرة بطريقة المربعات الصغرى الإعتيادية

مثال (1) : افترض اننا حصلنا من عينة ذات حجم (n=20) على تقدير لدالة الإستهلاك :

$$\hat{C} = 100 + 0.70Y$$

(75.5) (0.21)

إن الأرقام بيت الأقواس هي الأخطاء المعيارية لمعلمات $(100 = \hat{b}_0)$ $(0.70 = \hat{b}_1)$ ، لأن حجم العينة أقل من (30) مشاهدة فليس بالإمكان إستعمال إختبار (Z) ، ولكن نحن نعلم الإفتراضات الإحتتمالية (Stochastic Assumptions) حول قيم المتغير العشوائي (U) فإن التقديرات موزعة توزيعاً طبيعياً ، ولذلك نستطيع إختبار (t) نجد أن :

$$t^* = \frac{\hat{b}_1}{\hat{\delta}(\hat{b}_1)} = \frac{0.70}{0.21} \approx 3.3$$

نريد أن نختبر الفرضية (العدم) كما يأتي :

$$H_0 : b_1 = 0$$

ضد الفرضية البديلة :

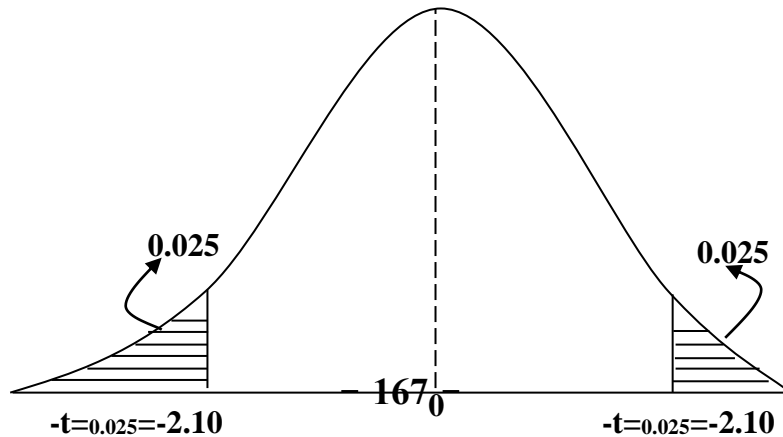
$$H_1 = b_1 \neq 0$$

القيم الحرجة لـ (t) بالنسبة الى (18=n-k) مقابل هذا نجد قيمة (t) :

$$t_1 = -t_{0.025} = -2.10$$

$$t_2 = +t_{0.025} = +2.10$$

إن المنطقة الحرجة مرسومة في الشكل (4-7) :



شكل (4-7)

الفصل السابع

الإختبارات الإحصائية لمعنوية المعلمات المقدرة بطريقة المربعات الصغرى الإعتيادية

لأن $(t^*=3.3)$ أكبر من القيمة الجدولية لـ (t) (2.10) في مستوى (0.025) ، فإننا نرفض الفرضية العدمية ونقول أن (b_1) هي مختلفة عن الصفر .

مثال (2) : إذا كانت لدينا المعلومات الآتية عن دالة العرض :

$$\hat{Y} = 33.75 + 3.25X$$

$$\delta_{(\hat{b}_0)} = \sqrt{\delta_u^2 \frac{\sum X_i^2}{n \sum (X_i - \bar{X})^2}} = 8.28$$

$$\delta_{(\hat{b}_1)} = \sqrt{\delta_u^2 \frac{1}{\sum (X_i - \bar{X})^2}} = 0.89$$

الآن نجد قيمة (t^*) لكل من (\hat{b}_1) و (\hat{b}_0) :

$$t^*(\hat{b}_0) = \frac{\hat{b}_0}{\hat{\delta}_{(\hat{b}_0)}} = 4.07$$

$$t^*(\hat{b}_1) = \frac{\hat{b}_1}{\hat{\delta}_{(\hat{b}_1)}} = 3.62$$

ومن الواضح ان كلا القيمتين لـ (t^*) هي عالية وهذا يعني أن التقديرات هي إحصائياً ذات معنوية عالية .

الفصل السابع

الإختبارات الإحصائية لمعنوية المعلمات المقدرة بطريقة المربعات الصغرى الإعتيادية

6-7 حدود الثقة للمعلمات b_0 و b_1

إن رفض فرضية العدم (Null Hypothesis) لا يعني أن تقديراتنا لـ (\hat{b}_1) هي تقديرات صحيحة للمعلمات الإحصائية للمجتمع الإحصائي ، ولكن ذلك يعني أن تقديراتنا للمعلمات قد جاءت من عينة إحصائية أخذت من مجتمع إحصائي معلماته تختلف عن الصفر ، من أجل أن نرى الى أي مدى تقترب تقديراتنا لـ (b_i) من المعلمات الحقيقية (True parameters) يجب أن نضع حدود الثقة (Confidence intervals) للمعلمات الحقيقية ، بعبارة أخرى نقوم بوضع قيم محددة تكون ضمنها تقديرات المعلمات ، لذلك نقول أنه بمستوى معطى من الإحتمالية ، فإن معلمة المجتمع الإحصائي سيكون ضمن حدود الثقة المذكورة أو المحددة .

نقوم بإختيار نسبة الإحتمال (a probability) مسبقاً ونشير إليها ، وندعوها مستوى الثقة (Confidence Level) . لقد أصبح من المعتاد في علم الإقتصاد القياسي إختيار 95% مستوى ثقة ، وهذا يعني أنه في حالة إعادة أخذ العينات فإن حدود الثقة (Confidence limits) والمحتسبة من العينة سوف تتضمن أو تحتوي على المعلمة الحقيقية للمجتمع الإحصائي في 95% من الحالات وهناك 5% من الحالات تكون فيها المعلمة الحقيقية للمجتمع الإحصائي خارج حدود الثقة .

1-6-7 حدود الثقة من إختبار (Z)

لقد ذكرنا سابقاً إنه بالإمكان إستخدام توزيع (Z) في حالة معرفة الانحراف المعياري للمجتمع الإحصائي $(\delta_{(\hat{b})})$ ، أو في حالة توفر عينة إحصائية كبيرة (n أكبر من 30) ، وذلك لإن العينات الكبيرة لها إنحراف معياري (δ) يعد تقديراً جيداً للانحراف المعياري للمجتمع الإحصائي المجهول إن (Z) للمعلمات (\hat{b}_i) هو :

الفصل السابع

الإختبارات الإحصائية لمعنوية المعلمات المقدرة بطريقة المربعات الصغرى الإعتيادية

$$Z = \frac{\hat{b}_i - b_i}{\delta(\hat{b}_i)}$$

إن واجبنا الأول هنا هو إختيار مستوى الثقة ولنقل 95% ، بعدها ننظر الى الجدول النظري (Standard normal table) ونجد أن إحتمال قيمة (Z) تقع بين (1.96-) و (1.96+) في مستوى الثقة 95% وهذا يمكن التعبير عنه كما يأتي :

$$P\{-1.96 < Z < +1.96\} = 0.95$$

نعوض عن قيمة (Z) :

$$P\left\{-1.96 < \frac{\hat{b}_i - b_i}{\delta(\hat{b}_i)} < 1.96\right\} = 0.95$$

$$P\left\{\hat{b}_i - 1.96(\delta_{(\hat{b}_i)}) < b_i < \hat{b}_i + 1.96(\delta_{(\hat{b}_i)})\right\} = 0.95$$

وهكذا فإن حدود الثقة بمستوى 95% للمعلمة (b_i) هي :

$$\left\{\hat{b}_i - 1.96(\delta_{(\hat{b}_i)}) < b_i < \hat{b}_i + 1.96(\delta_{(\hat{b}_i)})\right\}$$

$$b_i = \hat{b}_i \pm (1.96) \cdot (\delta_{(\hat{b}_i)})$$

مثال حول حدود الثقة مع إختيار (Z) :

$$\text{إذا علمنا أن } (\hat{b} = 8.4) \text{ و } (\delta_{(\hat{b})} = 2.2)$$

بإختيار مستوى ثقة 95% نجد حدود الثقة :

$$b = 8.4 \pm 1.96 (2.2)$$

$$8.4 - 1.96(2.2) < b < 8.4 + 1.96(2.2)$$

$$4.1 < b < 12.7$$

الفصل السابع

الإختبارات الإحصائية لمعنوية المعلمات المقدرة بطريقة المربعات الصغرى الإعتيادية

وهكذا من العينة الإحصائية نستدل أن المعلمة الحقيقية المجهولة للمجتمع الإحصائي ستقع بين (4.1) و (12.7) مع إحتمال 95% .

2-6-7 حدود الثقة من إختبار (t)

إن الطريقة لبناء حدود الثقة من إختبار (t) هي مشابهة لطريقة بناء حدود الثقة من إختبار (Z) ، ولكن مع إختلاف واحد رئيس وهو في حالة إختبار (t) نأخذ في الحساب درجات الحرية (Degrees of Freedom) :

قانون (t) لإختبار (\hat{b}_i) مع درجات حرية (k-n) :

$$t = \frac{\hat{b}_i - b_i}{\delta(\hat{b}_i)}$$

أولاً : نختار مستوى 95% مستوى ثقة أو أي مستوى ثقة آخر ، وثم نجد القيمة الجدولية أو النظرية لـ (t) المقابلة لـ $(\pm t_{0.025})$ مع درجات حرية (k-n) ، وهذا يتضمن إن إحتمال أن يقع (t) بين $(-t_{0.025})$ و $(+t_{0.025})$ هو (0.95) مع درجات حرية (k-n) ، ويمكن كتابة الإحتمال بالطريقة الآتية :

$$P\{-t_{0.025} < t < +t_{0.025}\} = 0.95$$

$$\frac{\hat{b}_i - b_i}{\delta(\hat{b}_i)} : \text{نعوض عن (t) بما يساوي}$$

$$P\left\{-t_{0.025} < \frac{\hat{b}_i - b_i}{\delta(\hat{b}_i)} < +t_{0.025}\right\} = 0.95$$

$$P\left\{\hat{b}_i - t_{0.025} (\delta(\hat{b}_i)) < b_i < \hat{b}_i + t_{0.025} (\delta(\hat{b}_i))\right\} = 0.95$$

الفصل السابع

الإختبارات الإحصائية لمعنوية المعلمات المقدرة بطريقة المربعات الصغرى الإعتيادية

وهكذا فإن حدود الثقة بمستوى ثقة 95% بالمائة للمعلمة (b) عندما نستخدم عينة صغيرة في تقدير تلك المعلمة هي :

$$\left\{ \hat{b}_i - t_{0.025} (\delta_{(\hat{b}_i)}) < b_i < \hat{b}_i + t_{0.025} (\delta_{(\hat{b}_i)}) \right\}$$

مع درجات حرية k-n

$$b_i = \hat{b}_i \pm t_{0.025} (\delta_{(\hat{b}_i)}) \quad \text{أو}$$

مع درجات حرية k-n

إن معنى حدود الثقة بمستوى ثقة 95% للمعلمة (b_i) هو أن هناك إحتمال (0.95) أن تكون قيمة المعلمة الحقيقية للمجتمع الإحصائي تقع ضمن حدود الثقة $(\hat{b} \pm t_{0.025})$ (مع درجات حرية k-n) .

مثال : نفترض أننا قدرنا خط إنحدار من عينة مكونة من عشرين مشاهدة كما يلي :

$$\hat{Y} = 128.5 + 2.88X \quad \text{مع درجات حرية (k-n)} \\ (38.2) \quad (0.85) \quad 18 = 20 - 2$$

من جدول (t) نجد أن قيمة (t_{0.025}) مع (18) درجة حرية هي (2.10) لذلك فإن حدود الثقة بمستوى (0.95) للمعلمات هي :

$$b_0 = 128.5 \pm (2.10)(38.2) = 128.5 \pm 80.2 : (b_0) \text{ الى النسبة 1-}$$

$$b_1 = 2.88 \pm (2.10)(0.85) = 2.88 \pm 1.79 : (b_1) \text{ الى النسبة 2-}$$

وهكذا فإن القيمة الحقيقية لمعلمة التقاطع (b₀) تقع بين (48.3) و (208.7) وبالطريقة نفسها فإن قيمة معلمة الإنحدار الحقيقي (b₁) تقع بين (1.09) و (4.67) .

الفصل الثامن
تحليل التباين

تحليل التباين

1-8 مقدمة

إن تحليل التباين (ANOVA) Analysis of Variance هو أحد الطرق الإحصائية التي طورت من قبل (R.A.Fisher) لتحليل البيانات التجريبية، وفي بدايتها طبقت الطريقة في تحليل التجارب الزراعية (إستخدام أسمدة مختلفة أو بذور مختلفة) ، ولكن بعد ذلك مباشرة إتسع تطبيقها ليشمل حقول علمية أخرى في مجال البحث العلمي.

في طريقة تحليل التباين يمكن أن نقسم التباين الكلي (Total Variance) لمتغير معين الى عناصر مضافة (Additive Component) التي ربما تعزى الى عناصر مستقلة مختلفة ، إن هذه العناصر تعبر عن أسباب أو مصادر الانحراف أو التباين في المتغير الذي نقوم بدراسته ، عندما تطبق هذه الطريقة على البيانات التجريبية (Experimental Data) تأخذ تصميم معين للتجربة الذي يقرر عدد العناصر الملائمة أو الاسباب للانحراف والأهمية المنطقية لكل منها ، مثلاً نفرض ان لدينا عشرون قطعة من الارض التي نزرعها بالحنطة ونريد أن ندرس الانتاج لكل قطعة ، نستخدم بذور مختلفة وأسمدة مختلفة وأنظمة ري مختلفة ، وهكذا فإن الانحرافات في الانتاج ربما تعزى منطقياً الى ثلاثة عناصر :

$$X_1 = \text{نوع البذور} \quad X_2 = \text{نوع الأسمدة} \quad X_3 = \text{نوع الري}$$

وعند إستخدام طريقة تحليل التباين يمكن أن نقسم الانحراف الكلي في الإنتاج إلى ثلاثة عناصر مستقلة : عنصر يعود الى (X_1) وعنصر آخر يعود الى X_2 والعنصر الثالث الى X_3 .

من هذا التعريف لتحليل التباين يجب ان يكون واضحاً ان هذه الطريقة هي فكرياً تشبه تحليل الانحدار . ففي تحليل الانحدار فإن الهدف هو لتقرير العناصر التي تسبب الانحراف في قيم المتغير المعتمد .

لقد وجدنا في تحليل الانحدار ان الانحراف الكلي في قيم المتغير المعتمد ينقسم الى عنصرين : الانحراف ، الذي يوضحه خط الانحدار او المساحة المستوية ، والانحراف غير الموضح الذي تبينه نقاط شكل الانتشار حول خط الانحدار ، والأكثر من هذا فإن معامل الارتباط المتعدد (Multiple Correlation Coefficient) قد عد معبراً عن جزء من الانحراف الكلي الموضح بواسطة خط الانحدار أو المساحة المستوية ، لقد وجد أن (R^2) يساوي العناصر المسببة للانحرافات مضافة الى بعضها البعض ، ولكن هناك اختلافات مهمة جداً بين طريقة تحليل التباين وطريقة الانحدار ان الاختلاف الرئيس هو ان تحليل الانحدار يزودنا بقيم رقمية لتأثير مختلف العناصر التوضيحية على المتغير المعتمد ، فضلاً عن المعلومات المتعلقة بتقسيم مصادر الانحراف الكلي في (Y) في عدة عناصر مضافة بينما تحليل التباين يعطينا المعلومات الاخيرة حول مصادر الانحراف فقط .

ان طريقة تحليل التباين تستخدم في تحليل الانحدار لإجراء اختبارات المعنوية أو الأهمية المختلفة ، والأكثر أهمية من تلك الاختبارات ما يأتي :

1. اختبار معنوية خط الانحدار .
2. اختبار معنوية أو أهمية التحسن في توفيق خط الانحدار الذي يحصل من خلال ادخال متغيرات اضافية جديدة أو اضافية في الدالة .
3. اختبار التساوي بين معاملات (Coefficients) يتم الحصول عليها من عينات مختلفة .
4. اختبار العينة الاضافية من حيث أدائها في الانحدار او اختبار استقرار معاملات الانحدار .

5. اختبار المقيدات المفروضة على معاملات الدالة .

8-2 : طريقة تحليل التباين بوصفها طريقة إحصائية .

إن هدف هذه الطريقة هو تقسيم الانحراف الكلي لمتغير معين (حول وسطه الحسابي) الى عدة عناصر يمكن ان تعزى الى اسباب محددة ولتبسيط التحليل سوف نفترض أن هناك عنصر نظامي واحد فقط مؤثر في التغير قيد الدراسة ، إن أي انحراف لا يسببه المتغير التوضيحي (Explanatory Variable) يفترض أن يعد انحرافا عشوائيا او إنحرافاً يحصل بالصدفة (by Chance) نتيجة لأحداث عشوائية مختلفة . ولدينا سلسلة من قيم المتغير (Y) وقيم مرافقة لها للمتغير التوضيحي (X) .

إن طريقة تحليل التباين تركز على قيم المتغير (Y) وتدرس انحرافاتهما وقيم المتغير (X) تستخدم لتقسيم قيم (Y) في مجموعات فرعية وعينات فرعية، مثلاً مجموعة واحدة أو عينة واحدة تتضمن القيم الصغيرة للمتغير (X) .

ولكل عينة فرعية نقوم بتقدير الوسط الحسابي للمتغير (Y) بحيث نحصل على منظومة من المتوسطات الحسابية ، فإذا كان (X) (وهو أساس لتصنيف قيم Y_s الى عينات فرعية) سبباً مهماً للانحراف في (Y) (بمعنى أن X هو متغير توضيحي مهم) ، فإن الاختلاف بين المتوسطات الحسابية للعينات الفرعية سيكون كبيراً ، وهذا يبدو من خلال التشتت الكبير للمتوسطات الحسابية للعينات الفرعية لـ (Y_i 's) حول الوسط الحسابي المشترك أو العام (\bar{Y}) . وهذا بوساطة التباين الكبير في توزيع المتوسطات الحسابية ، وعلى العكس من ذلك اذا كان (X) مصدر غير مهم من مصادر الإنحراف في (Y) فإن الاختلاف بين المتوسطات الحسابية للعينات الفرعية سوف يكون صغيراً وهذه حقيقة سوف تظهر بصيغة تباين صغير في توزيع المتوسطات الحسابية الفرعية (\bar{Y}_i) حول الوسط الحسابي المشترك أو العام (\bar{Y}) :

أ- إن أهمية المتغير (X) بوصفه سبباً للانحراف في (Y) يحكم عليها من خلال الاختلاف أو الفرق (difference) بين المتوسطات الحسابية للعينات الفرعية (\bar{Y}_i s) التي بنيت على أساس قيم (X) .

ب- إن الفرق أو الاختلاف بين المتوسطات الحسابية يعكسه قيمة التباين في توزيع المتوسطات الحسابية للعينة .

لذلك فإن الاختلاف أو الفرق بين المتوسطات الحسابية ربما يدرس ويختبر مع تقدير لتباين المجتمع الإحصائي ، أحدهما تقدير (δ_Y^2) ويتم الحصول عليه من خلال جمع (pooling) لتباينات العينات الفرعية ، والآخر يتم الحصول عليه من صيغة توزيع العينات أو توزيع (\bar{Y}) .

إن المقارنة بين أي نوعين من التباين يمكن أن تطبق بوساطة إحصاء (F) (F statistic) وجداول (F) ، إحصاء (F) هي نسبة أي نوعين مستقلين من التباين الى بعضهما التي يتم الحصول عليها من بيانات العينة ، وكل تقدير يتضمن خسارة أو نقصان في درجات الحرية ، فإذا كان لدينا أي نوعين من تقديرات التباين المستقل الأول مع (U_1) من درجات الحرية (U_2) من درجات الحرية ، فإن النسبة بين التقديرين تأخذ توزيع (F) مع درجات حرية (U_1) و (U_2) ، ولهذا السبب فإن (F) يدعى نسبة التباين (Variance Ratio) أو معدل التباين ، أما الحرف (F) فهو يرمز الى إسم (Fisher) هو إسم العالم الذي ابتدع إحصاء (F) .

فإذا كانت تقديرات النوعين من التباين قريبة من بعضها البعض فإن النسبة بينهما سوف تقترب من قيمة الواحد ، فكلما كان الفرق بين أي نوعين من التباين كبيراً كلما كان معدل أو نسبة (F) كبيراً ، وهكذا وبعمامة فإن القيم العالية لـ (F) تعبر عن إن الفرق بين النوعين من التباين ذا أهمية كبيرة أو رفض

فرضية العدم (Null Hypothesis) التي تفترض أن ليس هناك إختلاف أو فرق مهم بين النوعين من التباين .

3-8 إختبار الفرق بين المتوسطات الحسابية

نفترض ثلاثة أنواع من البترول تستخدم لتشغيل السيارة :

النوع (A) الذي يتصف بـ(90) أوكتان (Octane)

النوع (B) الذي يتصف بـ(95) أوكتان

النوع (C) الذي يتصف بـ(100) أوكتان

وهنا نرغب في أن نعرف في ما اذا كانت هذه النواع الثلاثة من البترول تعطي الإستهلاك نفسه من البترول لكل ميل أم لا ؟ بمعنى آخر نريد أن نقارن أداء الإستهلاك للأنواع الثلاثة من البترول ، لنفترض أننا نستخدم كل نوع لمدة (10) أيام ونقيس عدد الأميال المقطوعة لكل غالون من البترول وهكذا نحصل على ثلاث عينات بحجم (10) مشاهدات لكل نوع من البترول ، وهذه المشاهدات مدونة في الجدول (8-1) بصيغة عدد الأميال لكل غالون من البترول .

جدول (1-8)				المجموع N
العينة (1) نوع البترول (A) N1 = 10	العينة (2) نوع البترول (B) N2 = 10	العينة (3) نوع البترول (C) N3 = 10	المجموع N=n1+n2+n3	32
32	35	44		30
30	38	46		35
35	37	47		33
33	40	47		35
35	41	46		34
34	35	43		29
29	37	47		32
32	41	45		36
36	36	48		34
34	40	47		35
				38
				37
				40
				41
				35
				37
				41
				36
				40
				44
				46
				47
				47
$\sum Y_{1i} = 330$	$\sum Y_{2i} = 380$	$\sum Y_{3i} = 460$		46
$\bar{Y} = \frac{\sum Y_{1i}}{n_1} = 33$	$\bar{Y}_2 = \frac{\sum Y_{2i}}{n_2} = 38$	$\bar{Y}_3 = \frac{\sum Y_{3i}}{n_3} = 46$		43
$\delta^2_1 = \frac{\sum_{i=1}^{n_1} (Y_{1i} - \bar{Y}_1)^2}{n_1}$	$\delta^2_2 = \frac{\sum_{i=1}^{n_2} (Y_{2i} - \bar{Y}_2)^2}{n_2}$	$\delta^2_3 = \frac{\sum_{i=1}^{n_3} (Y_{3i} - \bar{Y}_3)^2}{n_3}$		47
$= \frac{46}{10}$	$= \frac{50}{10}$	$= \frac{22}{10}$	$\bar{Y} = \frac{\sum_i \sum_i Y_{1i}}{N}$	45
$\delta^2_1 = 4.6$	$\delta^2_2 = 5.0$	$\delta^2_3 = 2.2$	$= 39$	48
				47
				$\sum_i \sum_i Y_{ii} =$
				$= 1170$

يمكن أن تفسر البيانات التي وضعت في الجدول (8-1) بوصفها ثلاثة عينات عشوائية بحجوم ($n_1=n_2=n_3=10$) مع متوسطات حسابية ($\bar{Y}_1 = 33$ ، $\bar{Y}_2 = 38$ ، $\bar{Y}_3 = 46$) ميل/غالون من البترول .

مشكلتنا هنا هي أن نتأكد هل الاختلاف أو الفرق بين هذه المتوسطات الحسابية مهم إحصائياً أو يمكن أن يعزى الى الصدفة (Chance) يجب أن نفترض أن العينات مأخوذة من ثلاثة مجتمعات إحصائية تتميز بأن لها توزيع طبيعي أو تقريباً طبيعي مع متوسطات حسابية (M_3, M_2, M_1) على التوالي مع إنحراف معياري (δ) متساو ، إن هذا الافتراض يتضمن أنه على الرغم من الاختلاف في محتوى البترول من الأوكتان من الأنواع الثلاثة من البترول ربما تؤثر على معدل إستهلاك البترول ، فإنه سوف لن يؤثر التشتت (dispersion) أو التباين في الأميال المقطوعة حول المتوسطات الحسابية ، بعبارة أخرى إذا أخذنا عدداً كبيراً من المشاهدات لكل نوع من البترول فإن التوزيعات الثلاثة التي سوف نحصل عليها سوف تكون قريبة من المنحنيات الطبيعية ، حيث تتصف التوزيعات بالإنحراف المعياري نفسه (δ) ، نريد أن نعرف في ما إذا كان هناك ثمة إختلاف أو فرق مهم إحصائياً بين المتوسطات الحسابية (μ_3, μ_2, μ_1) للمجتمعات الإحصائية الثلاثة :

نريد أن نختبر فرضية العدم (Null Hypothesis)

$$H_0 : \mu_2 = \mu_3 = \mu_1$$

مقابل الفرضية البديلة

$$H_1 : \mu_j \text{ غير متساوية}$$

فإذا كانت المتوسطات الحسابية الثلاثة متساوية وهذا يعني إذا كانت فرضية العدم صحيحة فإن المجتمعات الإحصائية الثلاثة ربما تعد بوصفها مجتمعاً إحصائياً كبيراً واحداً مع وسط حسابي :

$\mu (= \mu_3 = \mu_2 = \mu_1)$ مع إنحراف معياري (δ) وهذا يعني :

$$Y \sim N(\mu, \delta^2)$$

والعينات الثلاثة ربما تعد بوصفها عينات أخذت من مجتمع إحصائي واحد كبير ، وربما تكتب التوزيعات الآتية للمتوسطات الحسابية للعينات :

$$\bar{Y}_1 \sim N(\mu, \delta^2_{\bar{Y}_1}) \sim N(\mu, \frac{\delta^2}{n_1})$$

$$\bar{Y}_2 \sim N(\mu, \delta^2_{\bar{Y}_2}) \sim N(\mu, \frac{\delta^2}{n_2})$$

$$\bar{Y}_3 \sim N(\mu, \delta^2_{\bar{Y}_3}) \sim N(\mu, \frac{\delta^2}{n_3})$$

قلنا ضمن فرضية العدم ($\mu_3 = \mu_2 = \mu_1$) وربما نعد المجتمعات

الإحصائية الثلاثة تشكل مجتمع إحصائي كبير :

$$Y \sim N(\mu, \delta^2)$$

إن تقديراً للوسط الحسابي العام أو المشترك (μ) ربما يحسب من خلال

توسيع العينة ($n_1 = n_2 = n_3 = 30$) ومن البيانات الموجودة في الجدول (1-8)

نحصل على :

$$\hat{\mu} = \frac{\sum Y_i}{N} = \frac{\sum_j \sum_i Y_{ji}}{N} = \frac{1170}{30} = 39 = \bar{Y}$$

إن تقديراً لتباين المجتمع الإحصائي (δ^2) ربما نحصل بطريقتين :

أولاً : يمكن أن نحصل على تقدير غير متحيز لتباين المجتمع الإحصائي من الصيغة الآتية :

$$\hat{\delta}^2 = \frac{\sum_j n_j (\bar{Y}_j - \bar{Y})^2}{k - 1} \dots \dots \dots (1-8)$$

عندما تكون (k) عدد العينات المأخوذة .

البرهان : إن هذه الصيغة إشتقت من العلاقة بين تباين المجتمع الإحصائي (δ^2) وتباين توزيع العينات :

$$\delta^2_{\bar{Y}_j} = \frac{\delta^2}{n_j} \dots \text{or} \dots \delta^2 = \delta^2_{\bar{Y}_j} \cdot n_j$$

في مثالنا لدينا ثلاثة عينات ومن كل منها يمكن أن نحصل على تقدير مستقل لـ (δ^2) :

$$\hat{\delta}^2_1 = n_1 \cdot \delta^2_{\bar{Y}_1} = n_1 (\bar{Y}_1 - \bar{Y})^2 = 10(33-39)^2 = 360$$

$$\hat{\delta}^2_2 = n_2 \cdot \delta^2_{\bar{Y}_2} = n_2 (\bar{Y}_2 - \bar{Y})^2 = 10(38-39)^2 = 10$$

$$\hat{\delta}^2_3 = n_3 \cdot \delta^2_{\bar{Y}_3} = n_3 (\bar{Y}_3 - \bar{Y})^2 = 10(46-39)^2 = 490$$

عندما يكون (\bar{Y}) الوسط الحسابي المشترك أو العام (pooled) نأخذ المعدل الموزون (Weighted Average) لهذه التقديرات نحصل على :

$$\hat{\delta}^2 = \frac{1}{3} \sum_j^k n_j (\bar{Y}_j - \bar{Y})^2$$

من أجل الحصول على تقدير غير متحيز نستخدم درجات حرية (2=1-3) ، أو على نحو عام (1-k) إذا كان لدينا (k) من العينات ، وهكذا فإن التقدير الأول لتباين المجتمع الإحصائي يصبح :

$$\hat{\delta}^2 = \frac{\sum_{j=1}^k n_j (\bar{Y}_j - \bar{Y})^2}{k-1}$$

يجب أن يكون واضحاً الآن أن هذا التقدير لتباين المجتمع الإحصائي تم الحصول عليه من الفروقات بين المتوسطات الحسابية (\bar{Y}_j) والوسط الحسابي المشترك (\bar{Y}) للمجتمع الإحصائي .

وكما رأينا فإن المتوسطات الحسابية للعينات الإحصائية هي تقديرات غير متحيزة للمتوسطات ($\mu_3=\mu_2=\mu_1$) ، إن فرضية العدم كانت ($\mu^1=(\mu_3=\mu_2=\mu_1)$) لذلك إذا كانت هذه الفرضية صحيحة فإن المتوسطات

الحسابية للعينات $(\bar{Y}_3 \ \bar{Y}_2 \ \bar{Y}_1)$ يجب أن لا تختلف عن بعضها البعض ولا تختلف عن الوسط الحسابي للمجتمع الإحصائي (\bar{Y}) ، إن هذا يتضمن إذا كانت تلك الفرضية غير صحيحة فإننا نتوقع إن المتوسطات الحسابية للعينات $(\bar{Y}_3 \ \bar{Y}_2 \ \bar{Y}_1)$ ، يجب أن تختلف عن بعضها البعض بشكل كبير وكذلك تختلف عن الوسط الحسابي للمجتمع الإحصائي (\bar{Y}) : إن الفرق بين هذه المتوسطات الحسابية سيكون أكبر مما نعزیه الى الصدفة ، وهذا بدوره يتضمن أن تقدير $(\hat{\sigma}^2)$ لتباين المجتمع الإحصائي سوف يكون كبيراً إذا كانت فرضية العدم غير صحيحة ، وذلك لأن $(\hat{\sigma}^2)$ قد تم إحتسابه من الفروقات $(\bar{Y}_j - \bar{Y})^2$ وهكذا فإن التقدير $(\hat{\sigma}^2)$ هو عنصر حاسم في إختبار الفرق بين المتوسطات الحسابية لأحجام معينة من العينات (Samples) . من خلال طريقة تقديره يتبين أنه يعكس الإنحرافات (Variations) بين المتوسطات الحسابية للعينات ويدعى الإنحراف بين (Variation between) . ومن أجل إجراء إختبارنا يكفي أن نقارن التقدير مع تباين المجتمع الإحصائي الحقيقي $(\hat{\sigma}^2)$ ونرفض فرضية العدم إذا كان الإنحراف أو التباعد (divergence) بين $(\hat{\sigma}^2)(\hat{\sigma}^2)$ كبيراً ، ولكن في مثالنا وكما هي الحال في أغلب المشكلات الموجودة في عالم الواقع ، إن $(\hat{\sigma}^2)$ الحقيقي غير معروف مما يوجب علينا أن نحصل على قيمة أخرى مقدرة مستقلة من بيانات عينة إحصائية .

ثانياً : إن تقديراً لتباين المجتمع الإحصائي $(\hat{\sigma}^2)$ يمكن أن نحصل عليه من خلال عملية تباينات العينات الإحصائية ، والصيغة أو القانون الملائم هو :

$$\hat{\sigma}^2 = \frac{n_1 s^2 + n_2 s^2 + \dots + n_k s^2_k}{(n_1 + n_2 + \dots + n_k) - k}$$

عندما يكون : (s_j) = تباينات العينات الإحصائية

(n_j) = حجوم العينات

يجب أن نلاحظ أن :

$$\left. \begin{aligned} n_1 \delta^2_1 &= n_1 \frac{\sum (Y_{1i} - \bar{Y})^2}{n_1} = \sum (Y_{1i} - \bar{Y}_1)^2 \\ n_k \delta^2_k &= n_k \frac{\sum (Y_{ki} - \bar{Y}_k)^2}{n_k} = \sum (Y_{ki} - \bar{Y}_k)^2 \end{aligned} \right\} \dots\dots\dots (3-8)$$

وهكذا فإن $(n_1 \delta^2_1 + n_2 \delta^2_2 + \dots\dots\dots + n_k \delta^2_k)$ تعطي المجموع الكلي لتربيع الانحرافات لكل العينات (k) ، إن التباين المجموعي (pooled-Variance) وصيغته يمكن أن يعد بوصفه عملية ربط أو جمع كل العينات في عينة واحدة كبيرة وتقدير تباين المجتمع الإحصائي ، نعوض عن (3-8) في (2-8) نحصل على :

$$\hat{\sigma}^2 = \frac{\sum_i^{n_1} (\bar{Y}_{1i} - \bar{Y}_1)^2 + \sum_i^{n_2} (Y_{2i} - \bar{Y}_2)^2 + \dots\dots + \sum_i^{n_k} (Y_{ki} - \bar{Y}_k)^2}{N - k}$$

عندما يكون $n_k + \dots\dots\dots + n_2 + n_1 = N$

وباستخدام إشارة أو علامة التجميع المزدوج نحصل على :

$$\hat{\sigma}^2 = \frac{\sum_j^k \sum_i^{n_k} (\bar{Y}_{ji} - \bar{Y}_j)^2}{N - k} \dots\dots\dots (4-8)$$

إن هذا التقدير لتباين المجتمع الإحصائي تم الحصول عليه أو يمكن الحصول عليه من تباينات العينات (Sample Variances) التي تعكس الانحراف ضمن كل عينة . كما أن تباينات العينات لا تعتمد على فرضية العدم وتتأثر تلك التباينات بالفروقات (differences) بين المتوسطات الحسابية للعينات $(\bar{Y}_3 \ \bar{Y}_2 \ \bar{Y}_1)$. بعبارة أخرى نقول حتى لو كانت المتوسطات الحسابية مختلفة على نحو كبير ، بحيث يكون هناك ثلاثة مجتمعات إحصائية

لكل واحد منها وسطه الحسابي ($\mu_3=\mu_2=\mu_1$) ولكن كل تلك المجتمعات الإحصائية سوف يكون لها بالإفتراض التباين نفسه (δ^2) للمجتمعات الإحصائية المجمعة (pooled) ($\hat{\delta}^2$) الذي يعتمد على الانحراف ضمن (Variation within) قيم العينة ($Y_{i's}$ لكل عينة) والذي يدعى الانحراف ضمن (within Variation) ، نلاحظ الآن أن الانحراف في قيم (Y_i) في كل عينة يعبر عن إنحرافات بالصدفة ، لذلك فإن التقدير ($\hat{\delta}^2$) ربما يعد مقياساً للانحراف في قيم (Y_i) ذلك الانحراف الذي يمكن أن يعزى الى الصدفة .

الآن لدينا تقديرين غير متحيزين (Unbiased) لتباين المجتمع الإحصائي (δ^2) :

التقدير (1) يعكس الانحراف بين المتوسطات الحسابية للعينات ويعتمد على شرعية أو صحة فرضية العدم .

التقدير (2) يعكس الانحراف في قيم (Y_i) ضمن العينات ومستقل عن فرضية العدم .

إن هذين التقديرين مستقلين ، لذلك فإن النسبة بينهما يكون لهما توزيع (F distribution)(F) مع درجات حرية كما يأتي ($U_1 = k-1$) و ($U_2 = N-k$) .

$$F^* = \frac{\left[\sum_{j=1}^k n_j (\bar{Y}_j - \bar{Y})^2 \right] / (k-1)}{\left[\sum_{j=1}^k \sum_{i=1}^{n_j} (Y_{ji} - \bar{Y}_j)^2 \right] / (N-k)}$$

عندما يكون :

N_j = حجم العينة (jth Sample)

$N = \sum_{j=1}^k n_j$ = حجم العينة المكبرة الناتجة عن تجميع العينات

$K =$ عدد العينات

وهكذا يمكن وضع معدل أو نسبة التباين (Variance Ratio) بصيغة

منتظمة :

$$F^* = \frac{\text{التباين المقدر من الانحراف بين المتوسطات الحسابية للعينات}}{\text{التباين المقدر من الانحراف في قيم } (Y_i) \text{ للعينات}}$$

عندما لا تكون المتوسطات الحسابية ($\mu_3=\mu_2=\mu_1$) مساوية للتباين

المقدر من الفروقات بين المتوسطات الحسابية فإنها تكون كبيرة ولذلك فإن معدل التباين (F^*) سوف يصبح كبيراً ، فإذا كانت فرضية العدم صحيحة فإن نسبة التباين المشاهد سوف تقترب من قيمة الواحد :

إن الفرق المشاهد في المتوسطات الحسابية ($\bar{Y}_3 \ \bar{Y}_2 \ \bar{Y}_1$) في هذه الحالة غير أساسي أو غير مهم ، وربما يعزى الى الصدفة ، وهكذا فإن التقدير الذي يبدو في البسط (Numerator) من النسبة (F^*) سيكون في الحقيقة تقدير لتباين المجتمع الإحصائي المجهول نفسه الذي يقدر في المقام (denominator) في النسبة (F^*) .

إن نسبة التباين المشاهد (F^*) تقارن مع القيمة النظرية (The Theoretical Value of F) لـ (F) مع مستوى معنوية مختار مثلاً 5% وتلك القيمة النظرية نحصل عليها من جدول (F) مع :
($k-1 = U_1$) و ($N-k = U_2$) درجات حرية .

إن القيمة النظرية (القيمة الحاسمة) لـ (F) هي قيمة (F) التي نعرف لنا المنطقة الحاسمة أو الدرجة للاختبار بمستوى مختار من المعنوية ، اذا كانت (F^*) أكبر من (F) النظرية نرفض فرضية العدم ، وهذا يعني أننا نقبل إن الفرق بين المتوسطات الحسابية كبير ومهم ، ومن هذه الشواهد ربما نفهم أو

نستنتج أن المجتمعات الإحصائية التي تم سحب العينات الإحصائية منها تختلف عن بعضها البعض .

وإذا كانت (F^*) أصغر من (F) النظرية نقبل فرضية العدم وهذا يعني أننا نقبل أن المتوسطات الحسابية للعينات لا تختلف على نحو كبير أو مهم . وفي هذه الحالة ربما نقول أن بيانات العينة تزودنا بدليل بأنه ليس هناك إختلاف مهم أو كبير بين المتوسطات الحسابية للمجتمعات الإحصائية التي تم سحب العينات منها .

في مثالنا لدينا النتائج الآتية :

(1) تباين مقدر بين المتوسطات الحسابية للعينات :

$$\begin{aligned}\hat{\sigma}^2 &= \frac{\sum_{j=1}^k n_j (\bar{Y}_j - \bar{Y})^2}{k-1} \\ &= \frac{n_1 (\bar{Y}_1 - \bar{Y})^2 + n_2 (\bar{Y}_2 - \bar{Y})^2 + n_3 (\bar{Y}_3 - \bar{Y})^2}{3-1} \\ &= \frac{10(33-39)^2 + 10(38-39)^2 + 10(46-39)^2}{2} \\ &= 430\end{aligned}$$

(2) تقدير التباين ضمن القيم (within Variation) :

$$\begin{aligned}\hat{\sigma}^2 &= \frac{\sum_j \sum_i^{n_k} (\bar{Y}_{ji} - \bar{Y})^2}{N-k} \\ &= \frac{\sum_1^{10} (\bar{Y}_{1j} - \bar{Y}_1)^2 + \sum_1^{10} (\bar{Y}_{2j} - \bar{Y}_2)^2 + \sum_1^{10} (\bar{Y}_{3j} - \bar{Y}_3)^2}{30-3} \\ &= \frac{46+50+22}{27} = \frac{118}{27} \\ &\approx 4.37\end{aligned}$$

(3) نسبة التباين المشاهد (The Observed Variance Ratio) :

$$F^* = \frac{\left[\sum_{j=1}^k n_j (\bar{Y}_j - \bar{Y})^2 \right] / (k-1)}{\left[\sum_{j=1}^k \sum_{i=1}^{n_j} (Y_{ji} - \bar{Y})^2 \right] / (N-k)}$$

$$F^* = \frac{\hat{\delta}^2}{\hat{\delta}^2} = \frac{430}{4.37}$$

$$F^* = 98.39 \approx$$

(4) القيمة النظرية لـ (F^*) بمستوى معنوية (5%) مع درجات حرية $(k-1 = U_1)$ و $(27 = N-k = U_2)$ وجدت من جدول (F) كما يأتي :

$$F_{0.05} = 3.37$$

(5) لأن (F^*) أكبر من $F_{0.05} = 3.37$ نرفض فرضية العدم ، بمعنى أننا نقبل أن هناك ثمة فارق مهم في معدل الأميال التي تحصل من الأنواع الثلاثة للبتروول ، إن الاختبار المذكور آنفاً ربما يفحص بطريقة أخرى سوف تنظم طريقة تحليل التباين ، يمكن أن نحصل على تقدير ثالث لتباين المجتمع الإحصائي (δ^2) بإستخدام عينة موسعة أو مكبرة تشكل من العينات الثلاثة الفرعية والتقدير غير المتحيز سيكون :

$$\delta^{*2} = \frac{\sum_i^N (Y_i - \bar{Y})^2}{N-1} = \frac{\sum_{j=1}^k \sum_{i=1}^{n_j} (Y_{ji} - \bar{Y})^2}{N-1}$$

عندما يكون $N-1$ = درجات الحرية للتباين المقدر (δ^{*2}) فإذا أخذنا البسط للتقديرات الثلاثة لتباين المجتمع الإحصائي $(\delta^{*2}, \hat{\delta}^2, \delta^{*2})$ يمكننا أن نضع العلاقة الآتية بين تلك الصيغ :

$$\sum_{j=1}^k \sum_{i=1}^{n_j} (Y_{ji} - \bar{Y})^2 = \sum_{j=1}^k n_j (\bar{Y}_j - \bar{Y})^2 + \sum_{j=1}^k \sum_{i=1}^{n_j} (Y_{ji} - \bar{Y}_j)^2$$

$$\left(\begin{array}{c} \text{المجموع الكلي} \\ \text{لمربع الانحرافات} \end{array} \right) = \left(\begin{array}{c} \text{مجموع مربعات الانحرافات} \\ \text{بين المجموعات} \end{array} \right) + \left(\begin{array}{c} \text{مجموع مربعات الانحرافات} \\ \text{ضمن المجموعات} \end{array} \right)$$

وهذا يعني :

$$\left(\begin{array}{c} \text{الانحراف الكلي} \\ \text{في (Y)} \end{array} \right) = \left(\begin{array}{c} \text{الانحرافات بين} \\ \text{المتوسطات} \end{array} \right) + \left(\begin{array}{c} \text{الانحرافات ضمن} \\ \text{العينات} \end{array} \right)$$

البرهان : نبدأ من الصيغة على الجهة اليسرى ونشكل المطابقة :

$$(Y_{ji} - \bar{Y}) = (Y_{ji} - \bar{Y}_j) + (\bar{Y}_j - \bar{Y})$$

أو

$$(Y_{ji} - \bar{Y}) = (Y_{ji} - \bar{Y}_j) + (\bar{Y}_j - \bar{Y})$$

نقوم بتربيع الطرفين :

$$(Y_{ji} - \bar{Y})^2 = (Y_{ji} - \bar{Y}_j)^2 + (\bar{Y}_j - \bar{Y})^2 + 2(Y_{ji} - \bar{Y}_j)(\bar{Y}_j - \bar{Y})$$

نجمع كل القيم فنجد :

$$\sum_{j=1}^k \sum_{i=1}^{n_j} (Y_{ji} - \bar{Y})^2 = \sum_j \sum_i (\bar{Y}_j - \bar{Y})^2 + \sum_j \sum_i (Y_{ji} - \bar{Y}_j)^2 + 2 \sum_j \sum_i (Y_{ji} - \bar{Y}_j)(\bar{Y}_j - \bar{Y})$$

إن الجزء الأخير من هذه المتطابقة يساوي صفراً ، وطالما أن :

$$2 \sum_j \sum_i (Y_{ji} - \bar{Y}_j)(\bar{Y}_j - \bar{Y}) = 2 \sum_j \left[(\bar{Y}_j - \bar{Y}) \sum_i (Y_{ji} - \bar{Y}_j) \right]$$

واذا علمنا أن $(\sum_i (Y_{ji} - \bar{Y}_j) = 0)$ وذلك لأن هذه هي مجموع الانحرافات ضمن

المجموعات (groups) أو العينات لذلك :

$$\sum_j \sum_i (Y_{ji} - \bar{Y})^2 = \sum_j \sum_i (Y_{ji} - \bar{Y}_j)^2 + \sum_j n_j (\bar{Y}_j - \bar{Y})^2$$

$$\text{الانحرافات بين} + \text{انحرافات ضمن} = \text{الكلية}$$

إن هذا التعبير أو الصيغة يبين كيف أن المجموع الكلي لمربعات في

(Y) (في المجموعات مع بعض) ينقسم الى جزئين :

الجزء الأول من الانحرافات في (Y) يعود الى الفرق بين المتوسطات الحسابية الجزء الثاني من الانحرافات في (Y) يعود الى الصدفة (مثلاً المطر أو العوامل النفسية) .

لاحظ أن هذا التقسيم للانحراف الكلي الى أجزاء مضافة يبقى صحيحاً بغض النظر عن قبول فرضية العدم أم لا ، وفي مثالنا فإن الانحراف الكلي في قيم (Y) حول الوسط الحسابي المشترك ($\bar{Y} = 39$) هو :

$$\sum_j \sum_i (Y_{ji} - \bar{Y})^2 = 978$$

ومربعات الانحرافات بين المتوسطات الحسابية :

$$\sum_{j=1}^3 n_j (\bar{Y}_j - \bar{Y})^2 = 860$$

مربعات الانحرافات ضمن المجموعات أو العينات

$$\sum_j \sum_i (Y_{ji} - \bar{Y}_j)^2 = 118$$

واضحاً :

$$\text{ضمن} + \text{بين} = \text{المجموع}$$

$$118 = 860 + 978$$

وهذا التقسيم للتباين الكلي يبقى صحيحاً على الرغم من إثبات فشل فرضية العدم ، وهنا يمكننا أن نضع العلاقة بين درجات الحرية في كل واحد من التقديرات الثلاثة لتباين المجتمع الإحصائي :

أ- إن درجات الحرية للتباين الكلي (δ^2) هي (N-1) .

ب- إن درجات الحرية للتباين المقدر على أساس الفرق بين المتوسطات الحسابية ($\hat{\delta}^2$) هي (K-1) .

ج- إن درجات الحرية للتباين المقدر على أساس الانحرافات ضمن

المجموعات (العينات) $(\hat{\sigma}^2)$ هي $(N-K)$.

الآن من السهولة أن نضع الانحراف الكلي بالصيغة الآتية :

$$(N-1) = (N-K) + (K-1)$$

بين + ضمن = الكلي

مع المعلومات حول تقسيم الانحرافات الكلية (الانحراف الكلي في Y)

ودرجات الحرية المختلفة يمكننا أن نشكل جدول تحليل التباين :

مصدر الانحراف (1)	مجموع المربعات (2)	درجات الحرية (3)	متوسط المربعات (4) = (2) : (3)	F (5)
بين المتوسطات والوسط الحسابي العام ضمن العينات	$\sum_j n_j (\bar{Y}_j - \bar{Y})^2$ $\sum_j \sum_i n_{ji} \left(Y_{ji} - \bar{Y}_j \right)^2$	$k-1$ $v_1 = 1$ $=N-k$ $v_2 = k$	$\frac{\sum_j n_j (\bar{Y}_j - \bar{Y})^2}{k-1}$ $\frac{\sum_j \sum_i n_{ji} (\bar{Y}_{ji} - \bar{Y})^2}{N-k}$	$F^* = \frac{\sum_j n_j (\bar{Y}_j - \bar{Y})^2 / (k-1)}{\sum_j \sum_i n_{ji} (\bar{Y}_{ji} - \bar{Y}_j)^2 / (N-K)}$
الانحراف الكلي	$\sum_j \sum_i n_{ji} (Y_{ji} - \bar{Y})^2$	(N-1)		من الجدول (F) $v_1 = k-1$ $v_2 = N-k$

ملحوظة : k هو عدد الهينات المأخوذة من المجتمع الإحصائي

$$F^* = \frac{\text{بين}}{\text{ضمن}}$$

إن نسبة (F^*) نسبة التباين المشاهد تشكل من خلال تقسيم متوسطي

مربع الانحراف أو الأخطاء التي تبدو في العمود الرابع من جدول تحليل التباين

في مثالنا الرقمي فإن جدول تحليل التباين يبدو في الجدول

(3-8) الآتي :

جدول (3-8)

مصدر الانحراف	مجموع مربعات الانحرافات	درجات الحرية	متوسط المربعات	F*
بين ضمن	860 118	(3-1)=2 (30-3)=27	$\frac{860}{2} = 430$ $\frac{118}{27} = 4.37$	$F^* = \frac{430}{4.37}$ $= 98.4$
المجموع	978	(30-1)=29		من جدول F $F_{0.025}=3.37$ مع درجات حرية $U_1=2$ $U_2=27$

4-8 اختبار (F) لمعنوية خط الانحدار

في هذا المجال نحاول اختبار نماذج تحتوي على متغيرات توضيحية عدة، إن الاختبار يهدف الى تبين في ما اذا كانت المتغيرات التوضيحية تؤثر فعلاً وعلى نحو مهم على المتغير المعتمد ، ويمكن أن يأخذ اختبار معنوية خط الانحدار الشكل الآتي الذي يتضمن فرضية العدم :

$$H_0 : b_1 = b_2 = \dots = b_k = 0$$

ضد أو مقابل الفرضية البديلة :

$$H_1 : \text{إن كل } b_i \text{ لا تساوي صفر}$$

إذا كانت فرضية العدم صحيحة أو حقيقية (True) بمعنى إذا كانت كل المعلمات الحقيقية مساوية للصفر ، أي ليس هناك علاقة خطية بين المتغير (Y) والمتغيرات التوضيحية ، ولكن اختبار المعنوية الكلية للانحدار يمكن أن يجري باستخدام جدول تحليل التباين .

نحسب إنحدار (Y) على كل (X) مع بعض ونقدر :

$$\text{أ- المجموع الكلي لمربعات الانحرافات لـ } ((Y_i - \bar{Y})) \quad ((\sum (Y_i - \bar{Y}))^2)$$

ب- مجموع مربعات الانحرافات الموضحة من قبل المتغيرات التوضيحية مع بعض $((\sum (\hat{Y} - \bar{Y}))^2)$

ج- مجموع الانحرافات المتبقية وهي $(\sum \ell^2)$

من هذه الصيغ (terms) نستطيع أ، نضع التعبير الآتي :

$$\sum Y^2 = \sum \hat{Y}^2 + \sum \ell^2$$

نحصل على درجات الحرية لكل صيغة في المتطابقة :

درجات الحرية للصيغة $(\sum \hat{Y})$ هي $(k-1)$ عندما يكون $k = (k+1)$ هو

العدد الكلي للمعاملات $(b's)$ ومن ضمنها معلمة التقاطع .

درجات الحرية للصيغة $(\sum \ell^2)$ هي $(N-K)$ عندما يكون (N) حجم

العينة الإحصائية .

وأخيراً فإن درجات الحرية لمجموع المربعات هو :

$$(K-1) + (N-K) = N-1$$

وضمن هذه المعلومات ربما نحسب نسبة (F^*) بالصيغة الآتية :

$$F^* = \frac{\sum \hat{y}^2 / (K-1)}{\sum \ell^2 / (N-K)}$$

ونتيجة هذه الصيغة تقارن مع القيمة الجدولية لـ (F) (في مستوى

مختار من المعنوية) مع درجات حرية :

$$(N - k = \nu_2) \quad (k - 1 = \nu_1)$$

إذا كانت (F^*) أكبر من (F) نرفض فرضية العدم بمعنى أننا نقبل أن

الإنحدار ذا معنوية إحصائية عالية ، أي أنه ليس كل المعلمات تساوي صفراً ،

و إذا كانت (F^*) أصغر من (F) نقبل فرضية العدم بمعنى أننا نقبل فرضية

الفصل الثامن

تحليل التباين

العدم أن الإنحدار ليس ذا معنوية إحصائية عالية ، يمكن أن نلخص المعلومات المذكورة آنفاً بوصفها في جدول تحليل التباين :

مصدر الإنحراف	مجموع المربعات SS	درجات الحرية	متوسط مربعات الأخطاء	F*
X_1, X_2, X_4 X_K	$\sum \hat{y}^2$ $\sum \ell^2$	$U_1 = k-1$ $U_2 = N-k$	$\frac{\sum \hat{y}^2}{k-1}$ $\frac{\sum \ell^2}{N-k}$	$F^* = \frac{\sum \hat{y}^2 / (K-1)}{\sum \ell^2 / (N-K)}$ $\frac{R^2 / (k-1)}{(1-R^2) / (N-k)}$
المجموع	$\sum y^2$	$N-1$		من الجداول مع درجات F معنوية $U_1 = k-1$ $U_2 = N-k$

يمكن أن نبين أن نسبة (F) لإختبار المعنوية الكلية للإنحدار يمكن أن

تقلص الى

$$F = \frac{R^2 / (K-1)}{(1-R^2) / (N-K)}$$

عندما يكون :

$K =$ عدد المعلمات (b'_s) ومن ضمنها (b_0) معلمة التقاطع .

$N =$ عدد المشاهدات في العينة

البرهان :

معلوم لدينا أن :

$$F^* = \frac{\sum \hat{y}^2 / (K-1)}{\sum \ell^2 / (N-K)}$$

نعيد كتابة الصيغة أعلاه بالصيغة الآتية :

$$F^* = \frac{\sum \hat{y}^2}{\sum \ell^2} \cdot \frac{N - K}{K - 1}$$

نقسم البسط والمقام على $(\sum y^2)$ فنحصل على :

$$F^* = \frac{\frac{\sum \hat{y}^2}{\sum y^2}}{\frac{\sum \ell^2}{\sum y^2}} \cdot \frac{N - K}{K - 1}$$

ومعلوم أيضاً أن :

$$\frac{\sum \hat{y}^2}{\sum y^2} = R^2_{Y.X_1.X_2....X_k}$$

وإن :

$$\frac{\sum \ell^2}{\sum y^2} = 1 - R^2_{Y.X_1.X_2....X_k}$$

نعوض في (F^*) نجد أن :

$$F^* = \frac{R^2_{Y.X_1.X_2....X_k}}{1 - R^2_{Y.X_1.X_2....X_k}} \cdot \frac{N - K}{K - 1} = \frac{R^2 / (K - 1)}{(1 - R^2) / (N - K)}$$

يمكن ان نقول اذا وجد أن الانحدار ليس له معنوية عالية أي اذا كانت المتغيرات التوضيحية لاتوضح أو لاتفسر أية نسبة من الانحرافات في المتغير المعتمد ، فإننا نتوقع أن قيمة البسط في صيغة (F^*) سوف تكون صغيرة جداً ، بعبارة أخرى أن (F^*) سوف يقترب من الصفر ، إن القيمة الكبيرة لـ (F^*) تعني أن علاقة ذات معنوية إحصائية عالية ومهمة يعرضها الانحدار بين (Y) و (X_s) .

الفصل التاسع
مشكلات الإنحدار
مشكلة الارتباط الخطي المتعدد

مشكلات الإنحدار

مشكلة الارتباط الخطي المتعدد (Multicollinearity)

1-9 مقدمة

من الشروط الحاسمة لتطبيق طريقة المربعات الصغرى هو أن المتغيرات الخطية لا ترتبط ببعضها خطياً وبشكل تام أي أن $(Y_{xi}x_j \neq 1)$ ، إن التعبير أو المصطلح (Multicollinearity) يستخدم لتعبير عن وجود علاقات خطية أو علاقات قريبة من الخطية بين المتغيرات التوضيحية (Explanatory Variables) . فإذا ارتبطت المتغيرات التوضيحية ببعضها خطياً وبشكل تام أي إذا كان معامل الارتباط لتلك المتغيرات يساوي واحد ، فإن المعلومات المقدرة تصبح غير محدودة أو غير نهائية : بمعنى أنه من المستحيل الحصول على قيم رقمية لكل معلمة على نحو منفصل وإن طريقة المربعات الصغرى تتحطم ، من جهة أخرى إذا لم ترتبط المتغيرات التوضيحية ببعضها ، بمعنى إذا كان معامل الارتباط بين تلك المتغيرات يساوي صفراً فإن المتغيرات تصبح متغيرات متعامدة (Orthogonal) وليس هناك مشكلات تتعلق بتقدير المعلمات بقدر تعلق الأمر بمشكلة الارتباط الخطي المتعدد ، في الواقع الفعلي في حالة المتغير المتعامد (Orthogonal Variable) (X'_s) ليس هناك حاجة لإجراء تحليل الإنحدار المتعدد ، حيث أن كل معلمة يمكن أن تقدر بوساطة تحليل الإنحدار البسيط (Simple Regression) مع المتغير (Y) بصيغة :

$$Y = F(X_i)$$

ولكن في الممارسة العملية أو في الواقع العملي ليس هناك أي من الحالتين المتطرفتين (وهو ارتباط خطي متعدد وعدم وجود ارتباط خطي متعدد) في الغالب الأعم ، في معظم الحالات هناك درجة من الارتباط (Intercorrelation) بين المتغيرات التوضيحية يعود إلى الاعتماد المتبادل (Interdependence) بين المتغيرات أو بين حجوم إقتصادية عبر الزمن ، في

هذه الحالة فإن معامل الارتباط البسيط لكل زوج من المتغيرات التوضيحية سوف يأخذ قيمة بين الصفر والواحد وإن مشكلات الارتباط المتعدد ربما تمنع الدقة والاستقرار في المعلمات المقدرة (Parameter Estimates) ولكن التأثيرات التامة للارتباط المتعدد ولم يتم التأكد نظرياً منها بعد .

إن الارتباط الخطي المتعدد ليس حالة أما أن تكون موجودة أو غير موجودة في الدوال الإقتصادية ولكنها ظاهرة متأصلة (inherent) أو ملازمة في معظم العلاقات ، وذلك يعود الى طبيعة الحجوم الإقتصادية . ليس هناك دليل حاسم يتعلق بدرجة الارتباط الخطي المتعدد التي إن وجدت فإنها سوف تؤثر على نحو خطير في قيم المعلمات المقدرة . فمن البديهي عندما يتغير متغيران توضيحيان أنياً وبالطريقة نفسها يصبح من الصعب جداً قياس تأثير أحدهما على المتغير المعتمد على نحو منفصل ، على سبيل المثال إفتراض إن الإنفاق الإستهلاكي لفرد من الأفراد يعتمد على دخله والأرصدة السائلة لديه ، فإذا كان دخله وأرصده السائلة خلال فترة من الزمن يتغيران بالنسبة نفسها ، فإن تأثير أحدهما على الإستهلاك ربما يعزى خطأ الى المتغير الآخر ، لذلك فإن تأثيرات هذين المتغيرين في الإستهلاك لا يمكن بحثها بسبب وجود الارتباط العالي المتبادل (Intereorrelation) بينهما .

9-2 أسباب ظهور أو وجود مشكلة الارتباط الخطي المتعدد

إن مشكلة الارتباط الخطي المتعدد ربما تظهر لأسباب مختلفة :
أولاً : ثمة ميل للمتغيرات الإقتصادية للحركة بعضها مع بعض عبر الزمن ، إن الحجوم الإقتصادية تتأثر بالعناصر نفسها ، وبالنتيجة فإن هذه العناصر التي تقرر الحجوم الإقتصادية عندما تبدأ فعلها أو تأثيرها فإن المتغيرات أو الحجوم الإقتصادية تبين أو تظهر بنموذج سلوك واسع متشابه عبر الزمن . مثلاً في فترات الإزدهار أو النمو الإقتصادي فإن الحجوم الإقتصادية

الأساسية تنمو على الرغم من أن بقية الحجم تتباطئ خلفها ، وهكذا فإن الدخل والإستهلاك والإدخار والاستثمار والأسعار والإستخدام تميل الى الإرتفاع في فترات التوسع الإقتصادي وتميل الى الإنخفاض في فترات الركود ، إن النمو وعناصر الإتجاه الزمني في السلاسل الزمنية (Time Series) هي أكثر الأسباب خطورة في وجود أو ظهور مشكلة الإرتباط الخطي المتعدد .

ثانياً : إستخدام القيم المتباطئة أو المتخلفة زمنياً (Lagged Values) لبعض المتغيرات التوضيحية بوصفها عناصر مستقلة في العلاقة ، فالنماذج ذات التباطؤات أو التخلفات الموزعة (Distributed Lags) كانت قد أعطت نتائج مرضية أو جيدة في عدة حقول من الإقتصاد القياسي كما أن إستخدام تلك النماذج يتوسع بسرعة .

مثلاً في دوال الإستهلاك أصبح إعتيادياً إدخال مستوى الدخل للفترة السابقة أو الماضية جنباً الى جنب مع مستوى الدخل في الفترة الحالية مع بقية المتغيرات التوضيحية . وبالطريقة نفسها في دوال الإستثمار فإن التباطؤ أو التخلفات الموزعة التي تتعلق بمستويات النشاط الإقتصادي في الفترة السابقة قد أدخلت بوصفها متغيرات توضيحية ، أنه من الطبيعي أن تكون القيم المتتالعة لمتغير معين ترتبط بعضها ببعض ، مثلاً الدخل في الفترة الحالية يقرر جزئياً بقيمته في الفترة السابقة ، وهكذا فإن الإرتباط الخطي المتعدد بوصفه مشكلة في تحليل الإنحدار هي غالباً موجودة بالتأكيد في نماذج التباطؤ الموزع ، فإذا أخذنا بنظر الإعتبار كل الأسباب المذكورة آنفاً والتي تسبب وجود الإرتباط الخطي المتعدد فإنه يبدو واضحاً أن درجة معينة من الإرتباط الخطي المتعدد تظهر في معظم العلاقات الإقتصادية .

يجب أن نلاحظ أنه على الرغم من أن الإرتباط الخطي المتعدد عادة يكون موجوداً في بيانات السلاسل الزمنية ، ولكن في بعض الأحيان يكون موجوداً في بيانات المقطع العرضي (Cross Section data) أيضاً ، مثلاً في

عينة من بيانات المقطع العرضي للشركات الصناعية فإن العمل ورأس المال بوصفهما عناصر إنتاج غالباً ما يرتبطان ببعضهما ارتباطاً قوياً وذلك لأن الشركات الكبيرة تميل إلى أن يكون لها كميات كبيرة من العنصرين ، بينما الشركات الصغيرة عادة يكون لها كميات أصغر من العمل ورأس المال ، ولكن وجود الارتباط الخطي المتعدد يميل إلى أن يكون مشكلة عامة وأكثر خطورة في السلاسل الزمنية .

9-3 ما يترتب على وجود الارتباط الخطي المتعدد

إذا كان الارتباط الخطي بين المتغيرات التوضيحية ارتباطاً عاماً أي أن

$$(r_{xixj} = 1) \text{ عندئذ :}$$

أ- فإن المعلمات المقدرة تكون غير نهائية .

البرهان :افترض إن العلاقة الآتية مطلوب تقديرها

$$Y = b_0 + b_1X_1 + b_2X_2 + u$$

ونفترض أن $(X_1)(X_2)$ مرتبطان ببعضهما بعلاقة تامة أي أن :

$$X_2 = kX_1$$

عندما يكون k أي رقم ثابت إعتباطي .

إن قانوني تقدير معلمات هذه العلاقة (\hat{b}_1, \hat{b}_2) هما :

$$\hat{b}_1 = \frac{\sum(x_1 - \bar{x}_1)(Y - \bar{Y})\sum(x_2 - \bar{x}_2)^2 - \sum(x_2 - \bar{x}_2)(Y - \bar{Y})\sum(x_1 - \bar{x}_1)(x_2 - \bar{x}_2)}{\sum(x_1 - \bar{x}_1)^2\sum(x_2 - \bar{x}_2)^2 - (\sum(x_1 - \bar{x}_1)(x_2 - \bar{x}_2))^2}$$

$$\hat{b}_2 = \frac{\sum(x_2 - \bar{x}_2)(Y - \bar{Y})\sum(x_1 - \bar{x}_1)^2 - \sum(x_1 - \bar{x}_1)(Y - \bar{Y})\sum(x_1 - \bar{x}_1)(x_2 - \bar{x}_2)}{\sum(x_1 - \bar{x}_1)^2\sum(x_2 - \bar{x}_2)^2 - (\sum(x_1 - \bar{x}_1)(x_2 - \bar{x}_2))^2}$$

نعوض عن (X_2) بقيمة (kX_1) فنحصل على :

$$\hat{b}_1 = \frac{K^2 \sum (X_1 - \bar{X}_1)(Y - \bar{Y}) \sum (X_1 - \bar{X}_1)^2 - K^2 \sum (X_1 - \bar{X}_1)(Y - \bar{Y}) \sum (X_1 - \bar{X}_1)^2}{K^2 \left(\sum (X_1 - \bar{X}_1)^2 \right)^2 - K^2 \left(\sum (X_1 - \bar{X}_1)^2 \right)^2} = \frac{0}{0}$$

$$\hat{b}_2 = \frac{K \sum (X_1 - \bar{X}_1)(Y - \bar{Y}) \sum (X_1 - \bar{X}_1)^2 - K \sum (X_1 - \bar{X}_1)(Y - \bar{Y}) \sum (X_1 - \bar{X}_1)^2}{K^2 \left(\sum (X_1 - \bar{X}_1)^2 \right)^2 - K^2 \left(\sum (X_1 - \bar{X}_1)^2 \right)^2} = \frac{0}{0}$$

ولذلك فإن معاملات العلاقة (\hat{b}_2, \hat{b}_1) هي معاملات غير نهائية وليس هناك أية طريقة لإيجاد قيم منفصلة لكل معلمة من المعلمات .

ب- إن الخطأ المعياري للمعلمات يصبح كبيراً على نحو لانهائي .

إذا كان $(r_{X_1X_2} = 1)$ ، فإن الخطأ المعياري للمعلمات المقدرة يكون كبيراً

على نحو لانهائي :

البرهان : في نموذج المتغيران :

$$Y = b_0 + b_1X_1 + b_2X_2 + u$$

فإذا كان (X_1) مرتبط على نحو تام بالمتغير التوضيحي الثاني (X_2) أي

أن $(X_2 = kX_1)$ فإن تباينات (Variances) المعلمات المقدرة سوف تكون :

$$\text{Var}(\hat{b}_1) = \hat{\delta}_u^2 \frac{\sum (X_2 - \bar{X}_2)^2}{\sum (X_1 - \bar{X}_1)^2 \sum (X_2 - \bar{X}_2)^2 - (\sum (X_1 - \bar{X}_1)(X_2 - \bar{X}_2))^2}$$

$$\text{Var}(\hat{b}_2) = \hat{\delta}_u^2 \frac{\sum (X_1 - \bar{X}_1)^2}{\sum (X_1 - \bar{X}_1)^2 \sum (X_2 - \bar{X}_2)^2 - (\sum (X_1 - \bar{X}_1)(X_2 - \bar{X}_2))^2}$$

$$\text{Var}(\hat{b}_1) = \hat{\delta}_u^2 \frac{k^2 \sum (X_2 - \bar{X}_2)^2}{k^2 \sum (X_1 - \bar{X}_1)^2 \sum (X_1 - \bar{X}_1)^2 - k^2 (\sum (X_1 - \bar{X}_1))^2}$$

$$= \frac{\hat{\delta}_u^2 \sum (X_1 - \bar{X}_1)^2}{0} = \infty \quad \text{نعوض عن } (X_2) \text{ بقيمة } (kX_1) \text{ فنحصل على :}$$

وهكذا فإن تباينات المعلمات المقدرة تصبح لانهائية مالم يكن $(\delta_u^2 = 0)$

ولكن على كل حال ليس هناك سبب مسبق ليميل (δ_u^2) الى أن يكون صفراً عندما يزداد الارتباط المتعدد بين المتغيرات التوضيحية ، لتوضيح المشكلة لنأخذ المثال الآتي لعلاقة إقتصادية تتضمن ثلاثة متغيرات توضيحية ، لنفترض إن الإستهلاك الحقيقي لبلد معين هو :

$$Y = b_0 + b_1X_1 + b_2X_2 + b_3X_3 + u$$

عندما يكون :

$$(Y) = \text{الإستهلاك الكلي}$$

$$(X_1) = \text{دخل المناطق الريفية}$$

$$(X_2) = \text{دخل المناطق الحضرية}$$

$$(X_3) = \text{الضريبة على الدخل}$$

على أسس مسبقة نتوقع أن (b_1) أصغر من (b_2) طالما أن الميل الحدي للإستهلاك في المناطق الحضرية على نحو عام أكبر من الميل الحدي للإستهلاك (MPC) في المناطق الريفية .

نحن نرغب بالحصول على تقديرات للميول الفردية ، كذلك بقية المعلمات $(parameters)$. لنفترض أنه خلال الفترة التي تغطيها العينة (X_2, X_1) متساويان (بمعنى أن الدخل يوزع بالتساوي بين المناطق الريفية والمناطق الحضرية) وهذا يعني $(X_2 = X_1)$. في ظل هذه الظروف سوف يكون من غير الممكن أن نحصل على تقديرات مستقلة للمعلمات (b_2, b_1) وذلك لأن (X_2, X_1) يتغيران مع بعض ، وربما نعوض عن (X_2) بـ (X_1) فنحصل على :

$$Y = b_0 + b_1X_1 + b_2X_1 + b_3X_3 + u$$

$$Y = b_0 + (b_1 + b_2) X_1 + b_3X_3 + u$$

وهكذا فإن إسقاط واحد من المتغيرين المتساويين يعطينا تقديراً لمجموع المعلمتين وليس قيمة فردية لكل من (b_2, b_1) وهذا يعني أن مجموع $(b_1 + b_2)$ سوف يكون مشخصاً ، ولكن (b_2, b_1) غير مشخصة على نحو مستقل

(هناك علاقة قريبة بين الارتباط الخطي المتعدد والتشخيص الإحصائي) إذا كانت قيم (X) غير مرتبطة ببعضها إرتباطاً تاماً ولكن هناك درجة من الارتباط أي أن $(0 < r_{XIX_j} < 1)$ فإن تأثيرات الارتباط الخطي غير مؤكدة ، إن الدلائل من الدراسات الإقتصادية القياسية النظرية مع بيانات مسيطر عليها ، وكذلك من البحث التطبيقي هي دلائل تخضع للجدل وهي غير حاسمة أو غير مقنعة .

في بعض الدراسات فإن القيم المعلمات تصبح غير مستقرة (Unstable) كلما تم إدخال متغيرات مرتبطة إضافية مرتبطة بعضها الى الدالة أو كلما ازداد حجم العينة ، وفي دراسات أخرى فإن قيم تقديرات المعلمات لا تتأثر كثيراً أو تأثيراً مهماً ، والشيء نفسه بالنسبة للأخطاء المعيارية للتقديرات : ففي بعض الدراسات وجد أن بعض الأخطاء المعيارية للمعلمات المقدرة تزداد أو ترتفع على نحو كبير عندما يكون في الدالة متغيرات مرتبطة بعضها البعض (Collinear) ، بينما في أمثلة أخرى وجد أن الأخطاء المعيارية لم يحصل أن تأثرت بالارتباط الخطي المتعدد ، وهنا لابد لنا أن نؤكد على نقطتين أساسيتين :

أولاً : إن المعلمات المقدرة غير متحيزة إحصائياً $(E(\hat{b}_i) = b_i)$ حتى ولو كان الارتباط الخطي المتعدد (Multicollinearity) قوياً ، إن الصفة الإحصائية في عدم التحيز (Unbiasedness) في تقدير المعلمات بطريقة المربعات الصغرى الإعتيادية (OLS) لا تتطلب أن قيم (X) غير مرتبطة ببعضها .

من ناحية أخرى فإن العينات التي تكون فيها علاقة إرتباط خطي متعدد بين قيم (X) ربما تجعل المعلمات المقدرة غير دقيقة وغير مستقرة ، ولسوء الحظ ليس هناك قواعد راسخة لتقييم خطورة مثل تلك الأخطاء ، ولكن عدم إستقرار القيم المقدرة للمعلمات ربما يكون خطيراً جداً الى الحد الذي يؤدي فيه

الى تغيير إشارة المعلمات المقدرة كلما ازدادت درجة الارتباط الخطي ، هناك بعض الدلائل تشير الى أن زيادة الارتباط الخطي المتعدد ينتج عنها تغيرات في قيم المعلمات اعتماداً على أهمية كل متغير توضيحي ، والأهمية تقاس عادة من خلال معامل الارتباط البسيط بين (Y) وكل من قيم (X) (r_{yxi}) .

إن مثل هذه الدلائل كانت قد قادت عدداً كبيراً من المختصين في الإقتصاد القياسي الى القول إن تأثيرات الارتباط الخطي المتعدد على المعلمات المقدرة تعتمد على درجة قساوة الاعتماد المتبادل (interdependence) بين المتغيرات وعلى أهمية تلك المتغيرات التي تدخل في علاقات خطية مع بعضها البعض ، في أي دراسة معينة هناك متغيرات توضيحية أكثر أهمية من المتغيرات الأخرى ، مثلاً في دالة الطلب فإن سعر السلعة ودخل المستهلك وسعر البدائل القريبة من السلعة هي متغيرات أكثر أهمية من أسعار البدائل البعيدة للسلعة على أسس مسبقة بالنسبة للسلعة قيد الدراسة ، اذا كانت تلك المتغيرات التوضيحية حاسمة سترائجياً وحدثت وأنها مرتبطة ببعضها بقوة فإن خطورة مشكلة الارتباط الخطي المتعدد تكون أكبر مما في حالة كون تلك المتغيرات المرتبطة ببعضها تشكل عناصر ثانوية وذلك لأن العناصر الثانوية يمكن إسقاطها من التحليل دون التأثير على النتائج على نحو خطير .

ثانياً : يبدو أن كتاب عدة يقبلون أنه عندما يكون الارتباط الخطي المتعدد موجوداً في دالة فإن الأخطاء المعيارية للمعلمات المقدرة سوف تكون على نحو عام كبيرة ، ولكن هذا ليس صحيحاً دائماً وذلك لأن كلاً من البسط والمقام لقانون حساب التباينات سوف تكون متأثرة عادة بالصيغ التي تتضمن المجموع من منتجات (X_s) لذلك فإن الحجم النهائي لتباين (b_i) ربما لا يكون كبيراً .

يبدو أن لورنس كلاين (L.R.Klein) يقبل بأن الارتباط الخطي المتعدد ليس بالضرورة مشكلة مالم يكن ذلك الارتباط الخطي المتعدد أكبر نسبياً من درجة الارتباط المتعدد الكلي (Overall) بين كل المتغيرات آنياً .

يعتقد كلاين إن الارتباط الخطي يكون مؤذياً إذا كان :

$$r^2_{xixj} \geq R^2_{y.x1.x2 \dots \dots \dots X_n}$$

عندما يكون :

(r^2_{xixj}) = معامل الارتباط البسيط بين أي متغيرين توضيحيين (X_j, X_i) .

(R^2) = الارتباط الكلي للعلاقة التي يمثلها خط الإنحدار .

إن أسلوب كلاين هوجم من قبل كل من فرار (Farrar) وكلاوبر (Glauber) في بحث نشر في مجلة أمريكية "Multicollinearity in Regression Analysis" مشكلة الارتباط الخطي المتعدد في تحليل الإنحدار" نشر في مجلة عام 1967 " Review of Economics and Statistics " .

ومن ناحية أخرى يعتقد ثايل (Theil) إن النموذج مع أكثر من متغيرين من (X) حتى لو كانت الارتباطات بين المتغيرات التوضيحية صغيرة ربما تقود الى عدم أهمية المتغيرات إحصائياً وذلك يعود الى زيادة الأخطاء المعيارية ، ولكن لابد لنا ان نقول أن فريش (Frisch) أوضح أن الأخطاء المعيارية هي ليست كبيرة دائماً عند وجود الارتباط الخطي المتعدد ، وهكذا ربما نحصل على تقديرات للمعلومات غير دقيقة بسبب الارتباط الخطي المتعدد على الرغم من أن الأخطاء المعيارية لتلك التقديرات الخاطئة ربما لا تبينها .

ولتلخيص المناقشات ربما نقول أنه على الرغم من وجود إستثناءات على نحو عام فإن زيادة الأخطاء المعيارية تظهر عندما ندخل متغيرات ترتبط ببعضها بوصفها متغيرات توضيحية في الدالة .

وهكذا مع وجود الارتباط الخطي المتعدد في الدالة نواجه خطر الخطأ في التحديد وذلك بسبب أنه ربما نرفض المتغير الذي يظهر فيه الخطأ المعياري عالياً على الرغم من أن ذلك المتغير هو مقررأ مهماً للانحرافات في المتغير المعتمد .

9-4 إختبارات للكشف عن وجود الارتباط الخطي المتعدد

9-4-1 طريقة معتمدة على تحليل الحشد (طريقة فريش Frisch)

إن خطورة تأثير الارتباط الخطي المتعدد تبدو معتمدة على درجة الارتباط التبادل بين المتغيرات (Interrelation) ($r_{X_iX_j}$) التوضيحية ، وكذلك معامل الارتباط الكلي ($R_{Y.X_1X_2...X_n}$) معامل الارتباط للإنحدار ، وهكذا يمكن أن نقول إن الأخطاء المعيارية (standard Errors) ومعاملات الارتباط الجزئي (partial Correlation Coefficient) ($r_{X_iX_j}$) ومعامل الارتباط الكلي (R^2) يمكن أن تستعمل لإختبار وجود الارتباط الخطي المتعدد ، ولكن أي من هذه المعايير بنفسه لا يعد مثشراً كافياً أو مرضياً للارتباط الخطي المتعدد وذلك يعود الى الأسباب التالية :

أ- إن الأخطاء المعيارية الكبير لاتظهر مع الارتباط الخطي المتعدد (من الدلائل ما يخص دالة الإنتاج بصيغة كوب دوكلاس (Cobb-Douglas) والأكثر من هذا إن الأخطاء المعيارية الكبيرة ربما تظهر لأسباب مختلفة وليس فقط بسبب وجود علاقة خطية بين المتغيرات التوضيحية .

ب- إن الارتباطات بين المتغيرات التوضيحية ليس بحاجة الى ان تكون عالية حتى تتأثر قيم المعلمات (b_i) والأخطاء المعيارية لها تأثيراً سلبياً أو رديئاً، وهذا يعني أن ($r_{X_iX_j}$) ليس معياراً كافياً بحد ذاته .

ج- إن معامل الارتباط الكلي (Overall) (R^2) ربما يكون عالياً نسبة الى معاملات الارتباط بين المتغيرات التوضيحية ($r_{X_iX_j}$) ولكن ربما تبقى النتائج غير دقيقة على نحو كبير وليس ذات معنوية إحصائية ، (مع إشارات خاطئة

وأخطاء معيارية كبيرة) ، ولكن على كل حال فإن تركيبة أو توليفة (a combination) من هذه المعايير جميعها ربما تساعد في الكشف عن الارتباط الخطي المتعدد ، ومن أجل الحصول على القدر الممكن من المعرفة حول خطورة مشكلة الارتباط الخطي المتعدد نحاول أن نتبنى طريقة هي في جوهرها صيغة منقحة لطريقة فريش في تحليل الحشد أو طريقة تحليل خارطة الحزمة (Bunch-Map Analysis) ، والأسلوب هو وضع صيغة إنحدار بين المتغير المعتمد على كل متغير توضيحي على نحو مستقل ، وهكذا نحصل على إنحدارات أولية أو بسيطة ونقوم بفحص أو إختبار نتائجها على أساس معايير مسبقة ومعايير إحصائية ، ونقوم بإختيار الإنحدار البسيط الذي يبدو أنه يعطينا النتائج الأكثر احتمالاً أو حصولاً أو إمكانية الحصول على أسس مسبقة وأسس إحصائية ، ومن ثم ندخل تدريجياً متغيرات إضافية ونختبر تأثيرها على المعاملات المنفردة وعلى الأخطاء المعيارية وقيمة (R^2) .

إن المتغير الجديد المضاف يصنف أنه مفيد أو إنه متغير غير ضروري أو زائد (Superflous) أو متغير ضار أو مؤذي أو غير مرغوب فيه أو معيق أو كما يأتي :

- 1- إذا أدى المتغير الجديد الى التحسن في (R^2) دون أن يجعل المعاملات أو المعلومات غير مقبولة أو مخطوءة على أساس إعتبارات مسبقة ، فإن ذلك المتغير يعد أو يصنف أنه مفيد ويحتفظ به بوصفه متغيراً توضيحياً .
- 2- إذا لم يؤدي المتغير الجديد الى التحسن في (R^2) ولم يؤثر على قيم المعلومات المنفردة الى مدى كبير او مهم ، فإن المتغير يعد غير ضروري أو زائد ، ويجب أن يرفض بمعنى عدم ضمه الى مجموعة المتغيرات التوضيحية .
- 3- إذا أثر المتغير الجديد على إشارات وحجوم المعلومات الى مدى كبير فإن ذلك المتغير يعد ضاراً أو مؤذياً أو غير مرغوب فيه ، فإذا تأثرت المعلومات بطريقة بحيث تصبح غير مقبولة على أسس أو إعتبارات نظرية مسبقة ، عندئذ

ربما نقول بأن هذا يعد تحذيراً أن مشكلة الارتباط الخطي المتعدد في هذه الحالة الخطيرة ، إن المتغير الجديد مهم لكن بسبب الارتباطات المتبادلة مع المتغيرات المستقلة الأخرى فإن تأثيره لا يمكن أن يقوم إحصائياً بطريقة المربعات الصغرى الإعتيادية (Ordinary Least Squares) .

إن هذا لا يعني أننا نرفض أو يجب أن نرفض المتغير المؤذي أو الضار ، فإذا فعلنا ذلك فإننا سوف نهمل معلومات قيمة بالنسبة الى محاولتنا في الوصول الى أفضل تحديد للعلاقة ، فإذا حذفنا المتغير المؤذي أو الضار تماماً في محاولة لتجنب أثره المؤذي على بقية المعلمات فإننا يجب أن نضع في تفكيرنا أن هذه العملية ببساطة تترك تأثير ذلك المتغير ليتم إمتصاصه من قبل بقية المعلمات الأخرى (بحيث تكون قيمتها مختلطة Mixed) ، وإمتصاصه أيضاً قبل المتغير العشوائي الذي ربما يصبح مرتبطاً مع بقية المتغيرات التي تركت في الدالة ، وبالنتيجة مخالفة الفرض السادس لأنه في هذه الحالة فإن :

$$E(U_i X_j) \neq 0$$

مثال : الجدول (1-9) يحتوي على بيانات السلاسل الزمنية للفترة 1951-1968 حول الإنفاق على الملابس والدخل تحت التصرف والأرصدة السائلة والرقم القياسي لأسعار الملابس والرقم القياسي العام للأسعار لأحد البلدان ، والمطلوب في هذا المثال تقدير دالة الطلب على الملابس .

جدول (1-9)

السنة	الإنفاق على الملابس	الدخل تحت التصرف	الأرصدة السائلة	الرقم القياسي لأسعار الملابس 1963=100	الرقم القياسي العام للأسعار 1963=100
1959	8.4	82.9	17.1	92	94
1960	9.6	88.0	21.3	93	96
1961	10.4	99.9	25.1	96	97
1962	11.4	105.3	29.0	94	97
1963	12.2	117.7	34.0	100	100
1964	14.2	131.0	40.0	101	101
1965	15.8	148.2	44.0	105	104

1966	17.9	161.8	49.0	112	109
1967	19.3	174.2	51.0	112	111
1968	20.8	184.7	53.0	112	111

على أسس نظرية مسبقة نقول إن الإنفاق على الملابس يتأثر بكل العناصر الموجودة بياناتها في الجدول (1) لذلك فإن دالة الطلب على الملابس يجب أن تأخذ الشكل الآتي :

$$C = b_0 + b_1Y + b_2L + b_3P_c + b_4P_o + u$$

عندما يكون :

(C) = الإنفاق على الملابس .

(L) = الأرصدة السائلة .

(P_c) = سعر الملابس .

(Y) = الدخل تحت التصرف

(P_o) = سعر السلع الأخرى .

وبتطبيق طريقة المربعات الصغرى على هذه الدالة نحصل على

التقديرات الآتية :

$$C = -13.53 + 0.09Y + 0.015L + 0.199P_c + 0.34P_o$$

$$(7.5) \quad (0.03) \quad (0.05) \quad (0.09) \quad (0.15)$$

$$R^2 = 0.998 \quad \sum \hat{y}^2 = 28.15 \quad \sum \ell_i^2 = 0.33 \quad d = 3.4$$

وبتطبيق تحليل التباين لإختبار جودة توفيق الإنحدار :

$$F^* = \frac{\frac{\sum \hat{y}^2}{(k-1)}}{\frac{\sum \ell_i^2}{(n-k)}} = \frac{\frac{28.15}{4}}{\frac{0.33}{5}} = 15.6$$

طالما أن القيمة النظرية لـ (F) عند مستوى معنوية (0.05) مع درجات

حرية (4 = k-1 = v₁) (5 = n- k = v₂) هي (5.19) نرفض فرضية العدم ونقبل

الفرضية البديلة التي تنص على أن هناك علاقة ذات معنوية إحصائية عالية بين

الإنفاق على الملابس والمتغيرات التوضيحية ، ولكن كل المتغيرات التوضيحية مرتبطة ببعضها خطأً على نحو خطير وكما يبدو ذلك من معاملات الارتباط البسيط :

$$\begin{array}{lll} r_{yL} = 0.993 & r_{ypc} = 0.980 & r_{ypo} = 0.987 \\ r_{LPc} = 0.964 & r_{LPo} = 0.973 & r_{PcPo} = 0.991 \end{array}$$

للكشف عن تأثيرات الارتباط الخطي المتعدد نحسب الإنحدارات

البسيطة :

$$\begin{array}{lll} 1- \hat{C} = \hat{a}_0 + \hat{a}_1 Y & & \\ & = -1.24 + 0.118Y & r^2=0.995 \quad d=2.6 \\ & (0.38) \quad (0.002) & \\ 2- \hat{C} = \hat{b}_0 + \hat{b}_1 Pc & & \\ & = -38.51 + 0.516Pc & r^2=0.951 \quad d=2.4 \\ & (4.20) \quad (0.04) & \\ 3- \hat{C} = \hat{c}_0 + \hat{c}_1 L & & \\ & = 2.11 + 0.327L & r^2=0.967 \quad d=0.4 \\ & (0.81) \quad (0.02) & \\ 4- \hat{C} = \hat{d}_0 + \hat{d}_1 Po & & \\ & = -53.65 + 0.663Po & r^2=0.977 \quad d=2.1 \\ & (3.65) \quad (0.03) & \end{array}$$

نختار الإنحدار الأول $[C=f(Y)]$ بوصفه خطوة أولى في التحليل طالما

أن الدخل (Y) يبدو على أسس نظرية مسبقة هو المتغير التوضيحي الأكثر أهمية خلال المدة الزمنية قيد الدراسة ، عندئذ ندخل ببقية المتغيرات التوضيحية تدريجياً في الدالة والنتائج تبين في الجدول (2-9) :

جدول (2-9)

الدالة	\hat{b}_0 ثابت	\hat{b}_1 (Y)	\hat{b}_2 (P _c)	\hat{b}_3 (L)	\hat{b}_4 (P ₀)	R ²	d
C=f(Y)	-1.24 (0.37)	0.118 (0.002)				0.995	2.6
C=f(Y,P _c)	1.40 (4.92)	0.126 (0.01)	-0.036 (0.07)			0.996	2.5
C=f(Y,P _c ,L)	0.94 (5.17)	0.138 (0.02)	-0.034 (0.06)	-0.37		0.996	3.1
C=f(Y,P _c ,P ₀)	-12.76 (6.52)	0.104 (0.01)	-0.188 (0.07)		0.319 (0.12)	0.997	3.5
C=f(Y,P _c ,L,P ₀)	-13.53 (7.5)	0.097 (0.03)	-0.99 (0.09)	0.015 (0.05)	0.34 (0.15)	0.998	3.4

* ملحوظة : الأرقام بين الأقواس هي الأخطاء المعيارية للمعاملات المقدرة .

إن التغيرات في الدخل تبدو هي الأكثر أهمية في توضيح الإنحرافات في الإنفاق على الملابس ، إن إدخال المتغير (P_c) حسن معامل التحديد (R²) على نحو بسيط ، إن إشارات (\hat{b}) صحيحة ولكن الأخطاء المعيارية تبين أن (\hat{b}_2) ليست ذات معنوية إحصائية .

إن الارتباط المتبادل العالي بين (P_c و Y) لا يؤثر على استقرار أو معنوية (\hat{b}_1) .

إن إدخال الأرصدة السائلة لا يعطي تقديرات جيدة لـ (b_2) أو (b_3) ، واضح من التقدير أن الارتباط المتبادل العالي بين (P_c و L) يجعل من المستحيل الحصول على تقديرات ذات معنى منفصلة لكل من (b_2) و (b_3) ولكن تقدير المعلمة (\hat{b}_1) غير متأثر على الرغم من وجود الارتباط المتبادل الخطير بين (L , P_c , Y) ، وهكذا فإن (L) ربما يعد متغير غير ضروري أو

زائد ، وبإسقاط المتغير (L) وإدخال المتغير (P₀) في الدالة نحصل على توفيق جيد ، أي معامل تحديد (R²) أفضل أو يزداد قليلاً ، وإن كل المعلمات المقدرة أخذت الإشارة الصحيحة وهي ذات معنوية إحصائية ، ولكن على الرغم من الدرجة العالية من الارتباط الخطي بين كل المتغيرات التوضيحية فإن الأخطاء المعيارية ليست كبيرة .

إن الإنحدار مع كل المتغيرات التوضيحية الأربعة يبين أن تأثير الارتباط الخطي المتعدد غير خطير بالنسبة إلى (\hat{b}_1 ، \hat{b}_2) أما معلمة المتغير (L) (\hat{b}_3) فهي ليست ذات معنوية إحصائية ، وهكذا فإن المتغير (L) بوضوح هو متغير زائد أو غير ضروري ، إذاً فإن أفضل توفيق يمكن الحصول عليه من الدالة الآتية :

$$C = f(Y, P_c, P_0)$$

2-4-9 اختبار فرار - كلاوبر (Farrar-Glauber) للارتباط الخطي المتعدد (Multicollinearity)

نشر فرار وكلاوبر في عام 1967 بحثاً في مجلة إقتصادية* حاولا فيه عرض اختباراً إحصائياً للارتباط الخطي المتعدد ، وهو في الحقيقة عبارة عن منظومة من ثلاثة اختبارات ، حيث أن فرار وكلاوبر إستخدما ثلاثة أنواع من الإحصاء (Statistics) لإختبار الارتباط المتعدد .

الإختبار المتعدد أو الإحصاء الأولى هي مربع كاي (Chi-square) (χ^2) لإكتشاف وجود خطورة الارتباط الخطي المتعدد في الدالة التي تتضمن متغيرات توضيحية عدة ، والإختبار الثاني هو إختبار (F) لإكتشاف موقع المتغيرات الداخلة في إرتباط خطي متعدد ، الإختبار الثالث هو إختبار (t) وهذا الإختبار لغرض إيجاد نمط الارتباط الخطي المتعدد ، بمعنى

* D.E.Farrar and R.R.Glauber, "Multicollinearity in Regression Analysis" Review of Economics and Statistics Vol.49,1967 PP (92-107)

المساعدة في تقرير أي المتغيرات مسؤول عن ظهور الارتباط الخطي المتعدد ، لقد عدُ الارتباط الخطي المتعدد في عينة ما من قبل فرار وكلاوبر بوصفه إبتعاداً للقيم المشاهدة لـ (X_s) عن الأورثاكونالتي (Orthogonality) إذ إن أسلوبهما كان قد إنبثق من فكرة مفادها أنه إذا كان الارتباط الخطي المتعدد تاماً، عندئذ فإن المعلومات المقدرة تصبح غير نهائية وأن علاقات الارتباط المتبادل بين مختلف المتغيرات التوضيحية يمكن قياسها بواسطة معاملات (Coefficient) الارتباط المتعدد ومعاملات الارتباط الجزئي ، إن إختبارات فرار- كلاوبر يمكن أن نصفها بالإطار العام الآتي :

أولاً – إختبار مربع كاي (Chi-square test)

لإختبار خطورة أو قساوة الارتباط الخطي المتعدد في حالة تتضمن متغيرات توضيحية عدة ، إن الفرضية الموضوعة قيد الإختبار في هذه المرحلة هي إن جمع (X_s) في العينة هي أورثاكونال (Orthogonal) $(r_{xixj}=r \text{ and } r_{xixj}=0)$ ، لهذا من الملائم أن تقوم بعملية معيارية (To Standardise) للمتغيرات لحجم العينة وللانحراف المعياري ، إن العملية المعيارية تنفذ من خلال تقسيم كل المشاهدات لكل (X) والتي تعرض بصيغة الانحرافات عن وسطها الحسابي على (\sqrt{n}) مضروباً في الانحراف المعياري لـ (X) ، وهذا يعني القيمة المعيارية لـ (t^{th}) من المشاهدات لـ (j^{th}) من المتغير:

$$\frac{(X_{jt} - \bar{X}_j)}{\sqrt{n}(S_{xj})}$$

إن هذه العملية مساوية لتقسيم كل عنصر من عناصر محددة ، مجموع المربعات ومجموع منتجات (X) (معروضة بصيغة الانحرافات) على الجذور

التربيعية لمجموع مربعات الإنحرافات للمتغيرات التي تظهر في العنصر ، مثلاً
محددة (X) بصيغة الإنحرافات في نموذج الثلاث متغيرات هي :

$$\begin{vmatrix} \sum(x_1 - \bar{x}_1)^2 & \sum(x_1 - \bar{x}_1)(x_2 - \bar{x}_2) & \sum(x_1 - \bar{x}_1)(x_3 - \bar{x}_3) \\ \sum(x_1 - \bar{x}_1)(x_2 - \bar{x}_2) & \sum(x_2 - \bar{x}_2)^2 & \sum(x_2 - \bar{x}_2)(x_3 - \bar{x}_3) \\ \sum(x_1 - \bar{x}_1)(x_3 - \bar{x}_3) & \sum(x_2 - \bar{x}_2)(x_3 - \bar{x}_3) & \sum(x_3 - \bar{x}_3)^2 \end{vmatrix}$$

وللحصول على الشكل المعياري لهذه المحددة نقسم العنصر الأول فيها
على $\left(\sqrt{\sum(x_1 - \bar{x}_1)^2}\right)^2$ والعنصر الثاني
على $\left(\sqrt{\sum(x_1 - \bar{x}_1)^2} \sqrt{\sum(x_2 - \bar{x}_2)^2}\right)$ وهكذا وعلى نحو عام فإن العنصر
 $\left(\sum(x_i - \bar{x}_i)(x_j - \bar{x}_j)\right)$ يقسم على $\left(\sqrt{\sum(x_i - \bar{x}_i)^2} \sqrt{\sum(x_j - \bar{x}_j)^2}\right)$
لإعطاء العنصر المرافق للمحددة المعيارية ، بالنسبة لنموذج الثلاث متغيرات
فإن المحددة المعيارية هي كما يأتي :

$$\begin{vmatrix} \frac{\sum(x_1 - \bar{x}_1)^2}{\sqrt{\sum(x_1 - \bar{x}_1)^2} \sqrt{\sum(x_1 - \bar{x}_1)^2}} & \frac{\sum(x_1 - \bar{x}_1)(x_2 - \bar{x}_2)}{\sqrt{\sum(x_1 - \bar{x}_1)^2} \sqrt{\sum(x_2 - \bar{x}_2)^2}} & \frac{\sum(x_1 - \bar{x}_1)(x_3 - \bar{x}_3)}{\sqrt{\sum(x_1 - \bar{x}_1)^2} \sqrt{\sum(x_3 - \bar{x}_3)^2}} \\ \frac{\sum(x_1 - \bar{x}_1)(x_2 - \bar{x}_2)}{\sqrt{\sum(x_1 - \bar{x}_1)^2} \sqrt{\sum(x_2 - \bar{x}_2)^2}} & \frac{\sum(x_2 - \bar{x}_2)^2}{\sqrt{\sum(x_2 - \bar{x}_2)^2} \sqrt{\sum(x_2 - \bar{x}_2)^2}} & \frac{\sum(x_2 - \bar{x}_2)(x_3 - \bar{x}_3)}{\sqrt{\sum(x_2 - \bar{x}_2)^2} \sqrt{\sum(x_3 - \bar{x}_3)^2}} \\ \frac{\sum(x_1 - \bar{x}_1)(x_3 - \bar{x}_3)}{\sqrt{\sum(x_1 - \bar{x}_1)^2} \sqrt{\sum(x_3 - \bar{x}_3)^2}} & \frac{\sum(x_2 - \bar{x}_2)(x_3 - \bar{x}_3)}{\sqrt{\sum(x_2 - \bar{x}_2)^2} \sqrt{\sum(x_3 - \bar{x}_3)^2}} & \frac{\sum(x_3 - \bar{x}_3)^2}{\sqrt{\sum(x_3 - \bar{x}_3)^2} \sqrt{\sum(x_3 - \bar{x}_3)^2}} \end{vmatrix}$$

إن المحددات المعيارية لمقامات تقديرات المربعات الصغرى يمكن إعادة
كتابتها على نحو مختلف قليلاً على أن نتذكر أن عناصر الدايagonal
(diagonal elements) تساوي واحد والعناصر الأخرى هي عبارة عن
معاملات الارتباط البسيط بين المتغيرات التوضيحية ، وهكذا فإن المحددة

المعيارية يمكن أن تدعى "محددة الارتباط" وفي نموذج الثلاث متغيرات فإن المحددة المعيارية هي :

$$\begin{vmatrix} 1 & r_{X1X2} & r_{X1X3} \\ r_{X1X2} & 1 & r_{X2X3} \\ r_{X1X3} & r_{X2X3} & 1 \end{vmatrix}$$

ومن هذه الصيغ نستطيع أن نختبر بسهولة الحالتين المتطرفتين الأورثوكونالتي (Orthogonality) والارتباط الخطي المتعدد التام ، ففي حالة الارتباط الخطي المتعدد التام فإن معاملات الارتباط البسيط ($r_{X1X2}, r_{X2X3}, \dots$ ets) تساوي واحد ولذلك فإن قيمة محددة الارتباط المعيارية تساوي صفراً ، في نموذج المتغيرين لدينا :

$$\begin{vmatrix} 1 & r_{X1X2} \\ r_{X1X2} & 1 \end{vmatrix} = \begin{vmatrix} 1 & 1 \\ 1 & 1 \end{vmatrix} = 0$$

وفي حالة الأورثوكونالتي (Orthogonality) لـ (X_s) فإن معامل الارتباط البسيط لكل زوج من (X_s) يساوي صفراً ولذلك فإن قيمة محددة الارتباط المعيارية تساوي واحد ، في نموذج المتغيرين لدينا :

$$\begin{vmatrix} 1 & r_{X1X2} \\ r_{X1X2} & 1 \end{vmatrix} = \begin{vmatrix} 1 & 0 \\ 0 & 1 \end{vmatrix} = 1$$

يتبع هذا اذا كانت قيمة المحددة المعيارية تقع بين الصفر والواحد فإن هناك درجة من الارتباط الخطي المتعدد .

إن التحليل المذكور آنفاً يقترح أن الارتباط الخطي المتعدد ربما يعد بوصفه إبتعاداً عن الأورثوكونالتي ، فكلما كان الإبتعاد عن الأورثوكونالتي قوياً

أي أن قيمة المحددة تقترب من الصفر فإن درجة الارتباط الخطي المتعدد تكون أقوى والعكس بالعكس .

إبتداءً من هذه الحقيقة إقترح فرار وكلاوبر إختبار مربع كاي (χ^2) الآتي للكشف عن قوة الارتباط الخطي المتعدد عبر منظومة المتغيرات التوضيحية برمتها أو كلها .

إن الفرضية الأساسية هي :

H_0 : (Orthogonal) إن X كلها اورثاكونال

ضد الفرضية البديلة :

H_1 : (Orthogonal) إن Xs ليس اورثاكونال

وجد فرار وكلاوبر إن الكمية :

$$*\chi^2 = - \left[n - 1 - \frac{1}{6}(2k + 5) \right] \cdot \log_e [\text{قيمة المحددة المعيارية}]$$

عندما يكون :

$$*\chi^2 = \text{القيمة المشاهدة لمربع } \chi^2 \text{ (حسب العينة)}$$

$$n = \text{حجم العينة الإحصائية}$$

$$k = \text{عدد المتغيرات التوضيحية}$$

لها توزيع مربع (χ^2) مع درجات حرية تساوي $(v = \frac{1}{2}k(k-1))$ من

بيانات العينة الإحصائية نحصل على القيمة التجريبية لمربع كاي ($*\chi^2$) والتي نقارنها مع القيمة النظرية لمربع كاي بمستوى معنوية مختار (يمكن الحصول

على القيمة النظرية من جدول χ^2) مع درجات حرية $(v = \frac{1}{2}k(k-1))$ ، يجب

أن يكون واضحاً أن القيمة النظرية لمربع كاي (χ^2) هي القيمة التي تعرف المنطقة الحرجة (Critical Region) من الإختبار عند المستوى المختار من

المعنوية مع درجات الحرية الملائمة ، إذا كانت قيمة مربع كاي (χ^2) المشاهدة أكبر من القيمة النظرية لمربع كاي (χ^2) مع درجات حرية $\left[\frac{1}{2} k(k-1) \right]$ نرفض إفتراض الأورثوكونالتي (Orthogonality) بمعنى أننا نقبل بأن هناك إرتباط خطي متعدد في الدالة وكلما كانت قيمة مربع كاي المشاهدة (χ^2) عالية كلما كانت مشكلة الإرتباط الخطي المتعدد أكثر قساوة وخطورة .

أما إذا كانت القيمة المشاهدة لمربع كاي (χ^2) أصغر من القيمة النظرية لها ($\chi^2 < \chi^2$) فإننا نقبل إفتراض الأورثوكونالتي أي إننا نقبل بأنه ليس هناك مشكلة إرتباط خطي متعدد ذات معنوية في الدالة .

ثانياً - إختبار (F) لتحديد موقع الإرتباط الخطي .

من أجل إيجاد موقع العناصر التي تدخل في علاقة خطية متعددة قام فرار وكلاوبر بحساب معاملات الإرتباط المتعدد بين المتغيرات التوضيحية ($R^2_{X_1, X_2, X_3, \dots, X_k}$) وعلى نحو عام ($R^2_{X_1, X_2, X_3, \dots, X_k}$) وإختبار المعنوية الإحصائية بوصفها معاملات الإرتباط المتعدد مع إختبار (F) وكما يأتي :

لكل معامل إرتباط متعدد نحسب القيمة المشاهدة ل (F^*) :

$$F^* = \frac{(R^2_{X_1, X_2, \dots, X_k}) / (k-1)}{(1 - R^2_{X_1, X_2, \dots, X_k}) / (n - k)}$$

عندما يكون :

n = حجم العينة الإحصائية

k = عدد المتغيرات التوضيحية

الفرضية قيد الإختبار في هذه المرحلة هي :

$$H_0 : R^2_{X_1.X_2.X_3...X_k} = 0$$

والفرضية البديلة هي :

$$H_1 : R^2_{X_1.X_2.X_3...X_k} \neq 0$$

إن القيمة المشاهدة لـ (F^*) تقارن مع القيمة النظرية لـ (F) (من جدول (F) مع درجات حرية $(v_1 = (k - 1))$ $(v_2 = (n - k))$ عند مستوى معنوية مختار ، فإذا كانت قيمة (F^*) أكبر $(>)$ من (F) نقبل أن المتغير (X_i) يدخل في علاقة ارتباط خطي متعدد وهذا يعني أننا نرفض فرضية العدم ، إذا كانت قيمة (F^*) أصغر $(<)$ من (F) فإننا نقبل أن المتغير (X_i) غير داخل في ارتباط خطي متعدد .

ثالثاً - إختبار (t) لنمط الارتباط الخطي المعتمد

يهدف إختبار (t) الى اكتشاف المتغيرات التي تسبب الارتباط الخطي المتعدد ، ومن اجل إيجاد أي المتغيرات مسؤول عن الارتباط الخطي المتعدد نحسب معاملات الارتباط الجزئي بين المتغيرات التوضيحية وإختبار معنويتها الإحصائية مع إحصاءة (t) ، وللتذكير فقط نقول أن معامل الارتباط الجزئي بين أي متغيرين (X_i) (X_j) يبين درجة الارتباط بين المتغيرين مع بقاء كل المتغيرات الأخرى ثابتة ، وفي نموذج المتغيرين فإن معامل الارتباط الجزئي هو معامل الارتباط البسيط نفسه ، وفي نموذج الثلاث متغيرات فإن معاملات الارتباط الجزئي تعطى بالصيغة الآتية :

$$r^2_{X_1.X_2.X_3} = \frac{(r_{12} - r_{13} - r_{23})^2}{(1 - r^2_{23})(1 - r^2_{13})}$$

$$r^2_{X_1.X_3.X_2} = \frac{(r_{13} - r_{12} - r_{23})^2}{(1 - r^2_{23})(1 - r^2_{12})}$$

$$r^2_{X_2.X_3.X_1} = \frac{(r_{23} - r_{12} - r_{13})^2}{(1 - r^2_{13})(1 - r^2_{12})}$$

أما بالنسبة للنماذج ذات المتغيرات الأكثر من ثلاثة متغيرات توضيحية فإن صيغة مماثلة يمكن أن توضع :

$$H_0 : r_{X_i X_j \dots X_i X_2 \dots X_k} = 0$$

تختبر هذه الفرضية مقابل الفرضية البديلة :

$$H_1 : r_{X_i X_j X_2 X_3 \dots X_k} \neq 0$$

وعند إتمام تقدير معاملات الارتباط الجزئي نحسب معنوياتها الإحصائية

من خلال حساب إحصاءة (t^*) لكل واحد منها :

$$t^* = \frac{(r_{X_i X_j X_1 X_2 \dots X_k}) \sqrt{n-k}}{\sqrt{1 - r_{X_i X_j X_1 X_2 \dots X_k}^2}}$$

عندما يكون :

$r_{X_i X_j X_2 X_3 \dots X_k}$ يشير الى معامل الارتباط بين المتغير (X_i) والمتغير (X_j) .

إن القيمة المشاهدة لـ (t^*) تقارن مع القيمة النظرية لـ (t) مع درجات

حرية $(v = (n - k))$ بمستوى مختار من المعنوية .

إذا كانت (t^*) أكبر من (t) الجدولية نقبل أن معامل الارتباط الجزئي

بين المتغيرين (X_i) و (X_j) ذات معنوية إحصائية وهذا يعني ان المتغيرين

(X_i) و (X_j) هما مسؤولان عن الارتباط الخطي المتعدد .

إذا كانت قيمة (t^*) أصغر من قيمة (t) الجدولية نقبل بأن المتغيرين

(X_i) و (X_j) غير مسؤولان أو أنهما لا يسببان الارتباط الخطي المتعدد طالما

كان معامل إرتباطهما الجزئي ليس ذات معنوية إحصائية عالية .

مثال : لتطبيق الإختبارات المذكورة آنفاً على الارتبط الخطي المتعدد ،

نعطي نتائج دالة الكلفة محسوبة من قبل فرار وكلاوبر لصيانة البواخر ، وقد

استخدم في تقدير الدالة عينة من المقطع العرضي (a cross-section) لـ (96)

باخرة بصيغة :

$$\text{Log } Y = b_0 + b_1 \log x_1 + b_2 \log x_2 + \dots + b_7 \log x_7 + \log u$$

عندما يكون :

Y = كلفة صيانة الباخرة الواحدة في السنة (بآلاف الدنانير أو الدولارات)

X_1 = عمر الباخرة بالسنوات .

X_2 = حجم الباخرة (الإزاحة بآلاف الأطنان) .

X_3 = الزمن بين الصيانة الكلية .

X_4 = إستهلاك الوقود .

X_5 = متغير أصم (نوعية الوقود مثلاً ديزل أو بخار أو نووي) .

$X_5 = 1$ اذا كانت الباخرة تشتغل بالديزل

$X_5 = 0$ اذا لم تكن الباخرة تشتغل بالديزل

X_6 = متغير أصم (Dummy Variable)

$X_6 = 1$ اذا كانت الباخرة مزودة بالرادار

$X_6 = 0$ اذا كانت الباخرة غير مزودة بالرادار

X_7 = متغير أصم لوصف في ما اذا كانت الباخرة قد خضعت الى (FRAM)

(Fleet Rehabilitation And Modernization) .

$X_7 = 1$ اذا كان هناك (FRAM)

$X_7 = 0$ اذا لم يكن هناك (FRAM)

إن النتائج التي تم الحصول عليها من طريقة المربعات الصغرى

التقليدية هي :

$$R^2 Y.X_1 \dots \dots \dots X_7 = 0.80$$

قيمة (F) = 56 مع درجات حرية : ($v_1 = k - 1 = 7$) ، ($v_2 = n - k = 96 - 8 = 88$)

\hat{b}_1	\hat{b}_2	\hat{b}_3	\hat{b}_4	\hat{b}_5	\hat{b}_6	\hat{b}_7
0.34	0.40	-0.79	0.05	-0.03	0.11	-0.16
(0.03)	(0.08)	(0.09)	(0.10)	(0.09)	(0.04)	(0.06)

إن إختبار (F) الكلي والأخطاء المعيارية الصغيرة لمعظم التقديرات يقترح أن الانحدار ذا معنى بصيغة أن (Y) لا يعتمد فعلياً على منظومة من المتغيرات $(X_7 \dots X_2, X_1)$ ، لإختبار درجة الارتباط الخطي المتعدد فإن (χ^2) كان قد حسب ووجد أنه يساوي (261) ، إن القيمة النظرية لـ (χ^2)

عند مستوى معنوية (0.05) مع درجات حرية تساوي $\left[\frac{1}{2} k(k-1) = 21 \right]$ تساوي

(32.7) ، طالما أن (χ^2) هي أكثر كثيراً من $(\chi^2_{0.05})$ نخلص الى القول أن

هناك درجة مهمة من الارتباط الخطي المتعدد في الدالة .

ولإيجاد أي من المتغيرات يمكن إعتبارها متغيرات تسبب الارتباط

الخطي المتعدد ، نقوم بحساب معاملات الارتباط الخطي المتعدد وقيم (F) التي

ترافقها ضمن منظومة المتغيرات التوضيحية :

$R^2_{X1 \cdot X2X3 \dots X7} = 0.30$	$F_{X1} = 6.3$
$R^2_{X2 \cdot X1X3 \dots X7} = 0.57$	$F_{X2} = 19.9$
$R^2_{X3 \cdot X1X2 \dots X7} = 0.30$	$F_{X3} = 6.3$
$R^2_{X4 \cdot X1X2 \dots X7} = 0.76$	$F_{X4} = 47.5$
$R^2_{X5 \cdot X1X2 \dots X7} = 0.76$	$F_{X5} = 47.1$
$R^2_{X6 \cdot X1X2 \dots X7} = 0.46$	$F_{X6} = 12.7$
$R^2_{X7 \cdot X1X2 \dots X7} = 0.24$	$F_{X7} = 4.8$

من النتائج المذكورة آنفاً يبدو أن العناصر الأكثر تأثراً بالارتباط الخطي

المتعدد هي المتغير (X_4) (إستهلاك الوقود) والمتغير (X_5) (التشغيل بالديزل) .

وأخيراً من أجل إيجاد أي المتغيرات مسؤول عن الارتباط الخطي

المتعدد بين المتغيرين (X_5, X_4) نقوم بحساب معامل الارتباط الجزئي للمتغيرات

التوضيحية وكذلك قيم إحصائية (t) التي ترافق كل معامل من معاملات الارتباط

الجزئي .

إن الحسابات تبدو في الجدول (3-9) وتبين أن سبب الارتباط الخطي المتعدد يعود على نحو رئيس الى التداخل أو الارتباط المتبادل (intercorrelation) بين :

أ- بين (X_4) و (X_5)

ب- بين (X_5) و (X_6)

جدول (3-9)

	X_1	X_2	X_3	X_4	X_5	X_6	X_7
X_1 العمر							
X_2 الحجم	$r_{12}=0.13$ (1.27)						
X_3 الدائرة	$r_{13}=0.21$ (2.01)	$r_{23}=0.27$ (2.60)					
X_4 الوقود	$r_{14}=-0.35$ (-3.57)	$r_{24}=0.34$ (3.44)	$R_{34}=0.09$ (0.82)				
X_5 ديزل	$r_{15}=-0.27$ (1.27)	$r_{24}=0.21$ (-2.03)	$R_{35}=0.12$ (1.15)	$R_{45}=-0.68$ (-8.77)			
X_6 رادار	$r_{16}=0.45$ (4.72)	$r_{26}=0.08$ (0.78)	$R_{36}=-0.35$ (-3.51)	$R_{46}=0.31$ (3.13)	$R_{56}=0.50$ (5.51)		
X_7 FRAM	$r_{17}=0.34$ (3.38)	$r_{27}=-0.13$ (-1.27)	$R_{37}=0.06$ (0.59)	$R_{47}=0.40$ (4.06)	$R_{57}=0.27$ (2.68)	$R_{67}=-0.26$ (-2.55)	

* ملحوظة : الأرقام بين الأقواس تمثل قيم إختبار (t)

5-32109 بعض الحلول لمشكلة الارتباط الخطي المتعدد

إذا كانت مشكلة الارتباط الخطي المتعدد موجودة في الدالة فإن الحلول التي يتم تبنيها تختلف اعتماداً على قساوة مشكلة الارتباط الخطي المتعدد وعلى وفرة مصادر أخرى للبيانات (مثلاً عينة أكبر أو عينات المقطع العرضي

...الخ) وعلى أهمية العناصر الداخلة في الارتباط الخطي المتعدد وعلى الغرض الذي قدرت من أجله الدالة وإعتبارات أخرى .

- 1- إقترح بعض الكتاب أنه اذا لم تؤثر مشكلة الارتباط الخطي المتعدد على تقديرات المعلمات فإننا يمكن أن نتحمل وجودها في الدالة على الرغم من أن سلامة أو وحدة تقديرات المربعات الصغرى الى مدى معين تضعف .
- 2- كتاب آخرون يقترحون أنه اذا أثرت مشكلة الارتباط الخطي على بعض العناصر غير المهمة فبإمكان الفرد أن لا يدخل تلك العناصر في الدالة .
- 3- إن مشكلة الارتباط الخطي ربما تؤثر في جزء من مجموعة معلمات (\hat{b}_s) بينما بقية المقدرات ربما تبقى نوعاً ما مستقرة ويمكن الإعتماد عليها.

وفي هذه الحالة :

- أ- إن المعلمات المقدرة (\hat{b}_s) التي يعتمد عليها ربما تستخدم لأي غرض مثل التنبؤ (Forecasting) أو تشكيل السياسة التي تتطلب معلومات يعتمد عليها حول المعلمات الهيكلية (Structural Parameters) .
 - ب- إن كل التقديرات ربما تستخدم لغرض التنبؤ وذلك لأن نمط الارتباط الخطي المتعدد سوف يستمر بالوجود في فترة التنبؤ .
- ولكن اذا كانت مشكلة الارتباط الخطي المتعدد تؤثر على نحو خطير على المعلمات المقدرة للعناصر المهمة في الدالة فعلى الباحث أن يتبنى واحداً من الحلول التصحيحية الآتية :

- 1- تطبيق طرق تستخدم معلومات كمية خارجية ، ومن أهم هذه

الطرق:

أ- طريقة المربعات الصغرى المقيدة

(Restricted Least Squares) .

ب- طريقة جمع بيانات المقطع العرضي وبيانات السلاسل الزمنية ، والتي هي حالة خاصة في طريقة المربعات الصغرى المقيدة .

ج- صيغة دوربين (Durbin) للمربعات الصغرى المعممة (Generalised Least Squares) .

د- أسلوب التقدير المختلط

(Mixed Estimation Technique) الذي اقترح من قبل

ثيل (Theil) وكولد بركر (Goldberger) .

2- زيادة حجم العينة .

من الأمور التي اقترحت حديثاً أن الارتباط الخطي المتعدد ربما يمكن تجنبه أو تقليل أثره من خلال زيادة حجم العينة بجمع مشاهدات أكثر ، وهكذا يقول كرسث (Christ) بزيادة حجم العينة ، فإن التباين المشترك (Covariance) العالي بين الملاحظات المقدرة الناتج من وجود الارتباط الخطي المتعدد في المعادلة يقل أو يقلص وذلك لأن ذلك التباين المشترك يتناسب عكسياً مع حجم العينة ، وإن هذا صحيحاً أو حقيقةً فقط إذا كان الارتباط الخطي المتعدد بسبب أخطاء القياس كما هو الحال عندما يكون الارتباط المتداخل موجوداً في العينة الأصلية فقط وليس في المجتمع الإحصائي (X_s) .

فإذا كانت المجتمعات الإحصائية للمتغيرات مرتبطة ارتباطاً خطياً متعدداً وواضحاً فإن زيادة حجم العينة سوف لن يساعد في تقليل أو تقليص علاقات الارتباط الخطي المتعدد بين المتغيرات .

3- إحلال متغيرات مستقلة محل المتغيرات المتخلفة زمنياً

(Lagged Variables) في نماذج التخلف الموزع

(Distributed - Lag) .

في الوقت المعاصر هناك الكثير من البحث في الإقتصاد القياسي ووجهت البحوث فيه تجاه إستخدام القيم المختلفة زمنياً (lagged Values) للمتغيرات التوضيحية ، وهذا يعني أن الباحثين قد تعرفوا على حقيقة مفادها أن نمطاً معيناً من السلوك يتقرر ليس فقط بالقيم الحالية للمتغيرات التوضيحية ولكن أيضاً بالقيم الماضية (Past Values) لتلك المتغيرات ، على سبيل المثال أنماط الإستهلاك للأفراد تعتمد على الدخل الحالية (Current income) كما هي تعتمد على الدخل الماضية ، ولكن مستويات الدخل الحديثة أو الأكثر حداثة تمارس تأثيراً على قرارات الإستهلاك أكبر من تأثير المستويات الماضية للدخل ، وهكذا فإن الدالة الأصلية ربما تكتب كآتي :

$$Y_t = b_0 + b_1X_t + b_2X_{(t-1)} + b_3X_{(t-2)} + \dots + u_t$$

ولأسباب واضحة فإن القيم المتتالية X_{t-2}, X_{t-1}, X_t ... الخ لأي متغير توضيحي (X_i) غالباً مرتبطة ببعضها على نحو قوي جداً ، يمكن تجنب الارتباط الخطي المتعدد في هذه الحالة من خلال تبني مقترح كويك (Koyck) في إحلال القيم المتخلفة زمنياً (lagged Values) للمتغير التوضيحي (X_i) :

$$Y_t = b_0 + b_1X_t + PY_{t-1} + (u_t - Pu_{t-1})$$

في هذا النموذج وضعنا بدلاً من كل القيم المتخلفة زمنياً لـ (X) كل من (X_t) (Y_{t-1}) في الدالة ، حيث من المتوقع أن يكون هذين المتغيرين أقل ارتباطاً ببعضها من القيم المتخلفة لـ (X) .

4- إدخال معادلات إضافية في النموذج .

إن مشكلة الارتباط الخطي ربما تعالج اذا قمنا بإدخال معادلات إضافية في النموذج للتعبير عن علاقات ذات معنى بين المتغيرات ذات الارتباط الخطي المتعدد (X'_s) . عندما ننظر الى منظومة من المتغيرات المستقلة بإمكان الفرد أو الباحث في معظم الأحيان أن يجد علاقات بين (X'_s) وبقية المتغيرات الجديدة التي تجعل للعلاقة معنى إقتصادي ، وبصيغة مباشرة نقول أن الباحث

يعرض تلك العلاقات بصيغة معادلات آنية ، أو نماذج المعادلات الآنية اذا تم تشخيصها يمكن أن تقدر على وفق المعادلات الآنية والشكل المختزل (reduce form) بوصفها احدى طرق المعادلات الآنية سوف تتجاوز مشكلة الارتباط الخطي فإذا كان النموذج الجديد نموذجاً فوق التشخيص ، فإن الباحث ربما يستخدم معلومات إضافية لبعض المعلومات من أجل الوصول الى أو الحصول على قيم وحيدة لبقية المعلومات من الشكل المختزل .

الفصل العاشر
مشكلة الارتباط الذاتي

مشكلة الارتباط الذاتي

1-10 مقدمة

من الافتراضات المهمة في النموذج الخطي الكلاسيكي أن لا يكون هناك ارتباط ذاتي (Autocorrelation) أو ارتباط متسلسل (Serial Correlation) بين قيمة المتغير العشوائي في الفترة الزمنية الحالية وقيمة المتغير العشوائي في الفترة الزمنية اللاحقة لها ، أو نقول ليس هناك ارتباط بين حدود حد الإضطراب (u_i) (Disturbance Term) الداخل في دالة الانحدار للمجتمع الإحصائي .

2-10 طبيعة مشكلة الارتباط الذاتي

إن مصطلح الارتباط الذاتي (Autocorrelation) يمكن أن يعرف بوصفه الارتباط بين أعضاء سلاسل من المشاهدات المنظمة زمنياً (كما هي في بيانات السلاسل الزمنية) أو أعضاء المكان في حالة بيانات المقطع العرضي ، وفي سياق الانحدار فإن نموذج الانحدار الخطي الكلاسيكي يفترض أن مثل ذلك الارتباط الذاتي غير موجود في حدود الإضطراب وبصيغة المعادلات :

$$E : (u_i u_j) = 0 \quad i \neq j$$

ببساطة فإن النموذج الكلاسيكي يفترض أن حد الإضطراب لأي مشاهدة لا يتأثر بحد الإضطراب لأي مشاهدة أخرى ، مثلاً إذا كنا نتعامل بسلسلة زمنية فصلية تتضمن إنحدار الإنتاج على رأس المال والعمل بوصفها مدخلات (Inputs) ونفترض أن هناك إضراب للعمال يؤثر في الإنتاج في فصل واحد من فصول السنة وأنه ليس هناك سبب يدعو الى الاعتقاد أن هذا الإضراب سوف يؤثر في الإنتاج في الفصل التالي من السنة ، وهذا يعني إذا كان الإنتاج منخفضاً في هذا الفصل فليس هناك سبباً يدعو الى التوقع بأن الإنتاج في الفصل التالي سيكون أقل .

وبالطريقة ذاتها اذا كنا نتعامل مع بيانات المقطع العرضي التي تتضمن إنحدار المصروف الاستهلاكي للعائلة على دخل العائلة ، فإن تأثير الزيادة في دخل العائلة على إنفاقها الاستهلاكي فلا نتوقع أن ذلك يؤثر في الإنفاق الاستهلاكي لعائلة أخرى ، ولكن على كل حال اذا كان هناك اعتماد من هذا النوع فإننا لدينا ارتباط ذاتي ، وبصيغة الإشارات :

$$E : (u_i u_j) = 0 \quad i \neq j$$

في هذه الحالة فإن الإضطراب الذي سببه الإضراب في الفصل الحالي ربما يؤثر في الإنتاج في الفصل التالي أو القادم أو إن الزيادات في الإنفاق من قبل إحدى العوائل يؤثر في زيادة الإنفاق من قبل عائلة أخرى . لعل من المفيد أن ننظر الى بعض الأنماط من حالات الارتباط الذاتي وحالات عدم وجود الارتباط الذاتي المعروضة في الشكل (1-10)(e,d,c,b,a) الذي يبين أن هناك أنماط بين (u_i) يمكن أن نميزها أو نراها .

الشكل (1-10)(a) يبين النمط الدائري والشكل (1-10)(b) و (1-10)(c) يؤشران إتجاه خطي صاعد أو نازل لحدود الإضطراب بينما الشكل (1-10)(d) يؤشر الإتجاه الخطي والتربيعي في حدود الإضطراب . إن الشكل (1-10)(e) هو الوحيد الذي يبين عدم وجود نمط منتظم بين حدود الإضطراب وهنا يدعم إفتراض عدم وجود الارتباط الذاتي للنموذج الكلاسيكي في الإنحدار الخطي .والآن السؤال الطبيعي هو لماذا يحدث الارتباط الذاتي أو المتسلسل ؟

ثمة أسباب عدة بعضها كما يأتي :

1- القصور الذاتي (lenteria)

من الخصائص الملحوظة لمهظم السلاسل الزمنية الإقتصادية هي القصور الذاتي ، وكما هو معروف جيداً أن سلاسل زمنية مثل (GNP) أو الأرقام القياسية أو الإنتاج أو الاستخدام أو البطالة تتعرض للدورات (التجارية) وعندما نبدأ من قعر الركود الإقتصادي وعندما يبدأ الانتعاش الإقتصادي فإن

معظم هذه السلاسل الزمنية تبدأ بالحركة الى الأعلى في هذا التذبذب الى الأعلى، فإن قيمة السلسلة في نقطة احدة أكبر من قيمته في النقطة السابقة . وهكذا فإن هناك ثمة قوة دافعة أو زخم مبني في تلك السلاسل وتستمر تلك القوة الدافعة الى ان يحصل شيئاً (مثلاً زيادة في سعر الفائدة أو زيادة في الضرائب أو كليهما) ليبطيء أو ليقطع السلاسل أو يحركها الى الإنخفاض ، لذلك في الإنحدارات التي تتضمن بيانات سلاسل زمنية تكون المشاهدات المتتالية تدخل في علاقات متداخلة .

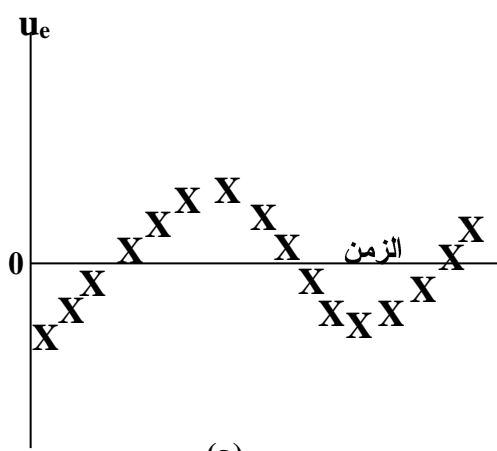
2- تحيز التحديد أو التوصيف (Specification Bias)

حالة إستبعاد متغيرات .

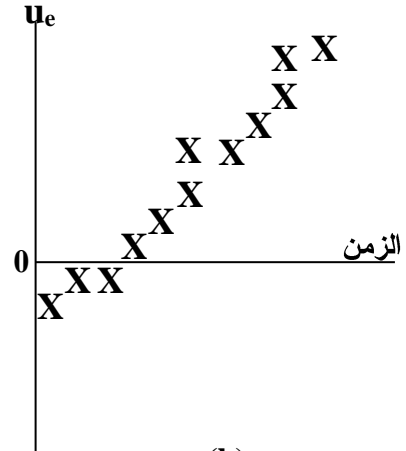
في التحليل التجريبي (Empirical Analysis) عادة يبدأ الباحث مع نموذج إنحدار ممكن ولكن ربما يكون غير تام ، بعد تحليل الإنحدار فإن الباحث يقوم بفحص في ما اذا كانت نتائج النموذج تتطابق مع التوقعات المسبقة ، فإذا لم تتطابق فإن عملية معينة يجب أن تجرى على النموذج ، مثلاً ربما يقوم الباحث برسم البواقي (e_i) (Residuals) التي يتم الحصول عليها من تحليل الإنحدار ، وربما يلاحظ الباحث مثل تلك الأنماط المرسومة في الشكل (1-10) إن هذه البواقي (وهي تقريبات proxies للمتغير العشوائي u_i) ربما تقترح إن بعض المتغيرات التي كانت أصلاً مرشحة ان تكون ضمن الدالة ولكنها لم تدخل في الدالة أو النموذج لأسباب مختلفة يجب أن تدخل في النموذج.

هذه هي حالة أبعاد المتغيرات التي تبين تحيزاً في التوصيف للنموذج ، غالباً ما يحدث إن إدخال مثل تلك المتغيرات في الدالة يحذف وجود نمط الارتباط المشاهد بين البواقي مثلاً نفترض أن لدينا نموذج الطلب الآتي :

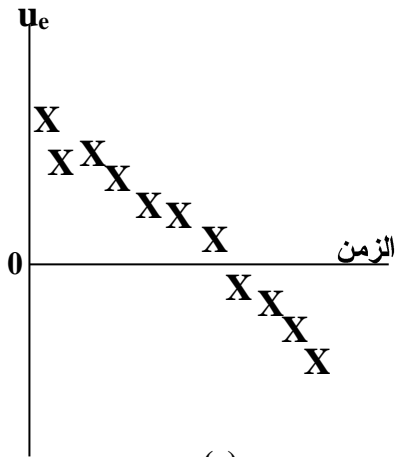
$$Y_t = b_1 + b_2X_{2t} + b_3X_{3t} + b_4X_{4t} + u_t \dots\dots(1-10)$$



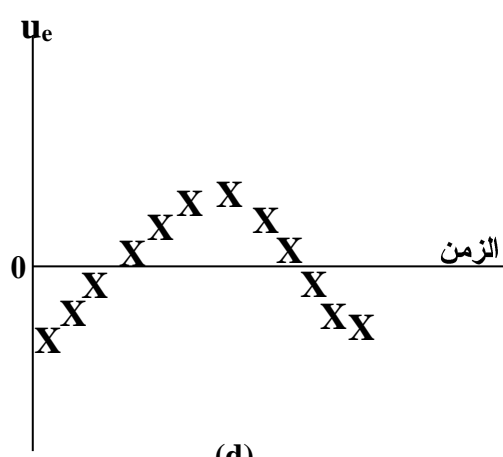
(a)



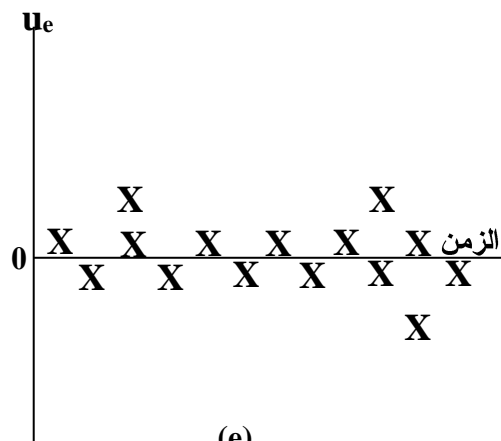
(b)



(c)



(d)



(e)

شكل (1-10)

عندما يكون :

$$Y = \text{كمية لحم البقر المطلوب}$$

$$X_2 = \text{سعر لحم البقر}$$

$$X_3 = \text{دخل المستهلك}$$

$$X_4 = \text{سعر لحم الخنزير}$$

$$t = \text{الزمن}$$

ولكن لبعض الأسباب نحدد الإنحدار التالي :

$$Y_t = b_1 + b_2X_{2t} + b_3X_{3t} + b_4X_{4t} + u_t \dots\dots(2-10)$$

الآن اذا كانت المعادلة (1-10) هي النموذج الصحيح او الحقيقي أو المعبر عن العلاقة الحقيقية ، فإن إستخدام المعادلة (2-10) معادل أو مساوي لجعل :

$$u_t = b_4X_{4t} + u_t \dots\dots\dots(3-10)$$

والى مدى أن سعر لحم الخنزير يؤثر في إستهلاك لحم البقر فإن حد الخطأ أو حد الإضطراب (u) سوف يعكس نمطاً أو نموذجاً منتظماً وهكذا خلق ارتباط ذاتي خاطيء ، والإختبار البسيط لهذا هو أن نستخدم النموذج (1-10) والنموذج (2-10) ونرى في ما اذا كان هناك ارتباطاً ذاتياً مشاهداً في النموذج (3-10) يختفي عندما نستخدم النموذج (1-10) .

3- الشكل الدالي غير الصحيح (Incorrect Functional Form)

لنفترض أن النموذج الحقيقي أو الصحيح في دراسة الكلفة - الإنتاج

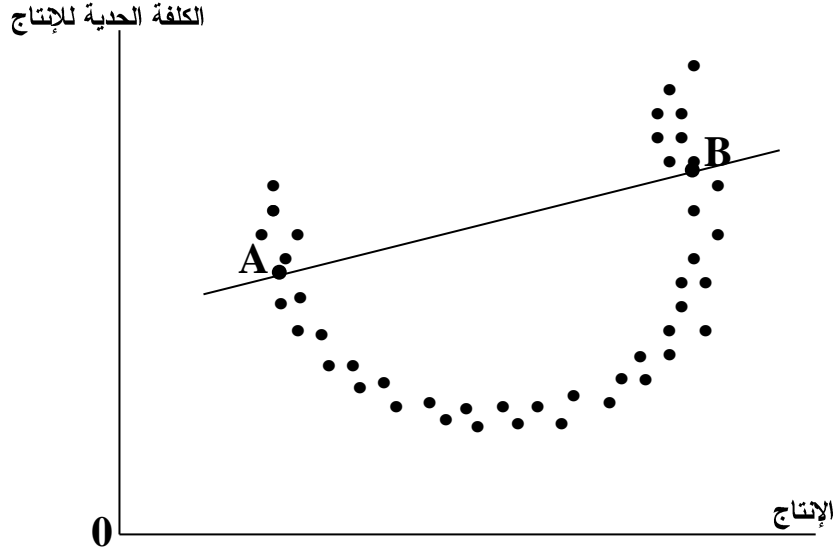
كما يأتي :

$$b_1 + b_2 (\text{الإنتاج}) + b_3 (\text{الإنتاج})^2 + u_i \dots\dots\dots(4-10) = \text{الكلفة الحدية}$$

ولكن اذا قدرنا النموذج الآتي :

$$b_1 + \alpha_1 + \alpha (\text{الإنتاج}) + u_i \dots\dots\dots(5-10) = \text{الكلفة الحدية}$$

إن منحنى الكلفة الحدية الذي يرافق النموذج الحقيقي يبدو في الشكل (2-10) مع منحنى الكلفة الخطي غير الصحيح :



شكل (2-10) يبين الشكل الدالي غير الصحيح

وكما يبدو في الشكل (2-10) فإن المسافة بين النقطتين (A)(B) تبين منحنى الكلفة الحدية الخطي الذي سوف يبين تقديراً للكلفة الحدية يفوق الكلفة الحدية الحقيقية ، بينما ما بعد النقطتين فإن المنحنى الخطي سوف يعطي تقديراً للكلفة الحدية أقل من الكلفة الحدية الحقيقية ، وهذا متوقع لأن حد الإضطراب (u_i) الذي يساوي في الواقع القيمة الآتية :

$$u_i + (\text{الإنتاج})^2$$

ولذلك فهو يمسك أو يعبر عن التأثير المنتظم لتربيع الإنتاج $(\text{الإنتاج})^2$ في الكلفة الحدية ، وفي هذه الحالة فإن (u_i) سوف يعكس الارتباط الذاتي بسبب استخدام الشكل الدالي غير الصحيح .

4- الظاهرة العنكبوتية (Cobweb Phenomenon)

إن العرض من عدة سلع زراعية يعكس ما يدعى بالظاهرة العنكبوتية ، والتي يكون فيها رد الفعل من قبل العرض الى السعر مع تخلف زمني لفترة واحدة ، وذلك لأن قرارات العرض تأخذ وقتاً للتنفيذ (فترة النضوج) ، وهكذا في بداية فترة زراعة المحاصيل لهذه السنة فإن المزارعين متأثرون بالأسعار السائدة في السنة السابقة بحيث تكون دالة العرض هي :

$$Q_s = b_0 + b_1 P_{t-1} + u_t$$

ولنفترض أنه في نهاية الفترة (t) وجدنا ان سعر السنة (t) (P_t) ظهر أنه أقل من (P_{t-1}) ، لذلك في الفترة (t+1) فإن المزارعين ربما يقررون أن ينتجوا أقل مما أنتجوا في الفترة (t) .

إذاً من الواضح في هذه الحالة أن قيم المتغير العشوائي (u_i) من غير المتوقع أن تكون عشوائية وذلك لأنه اذا أنتج المزارعون كميات أكثر في السنة (t) مما أنتجوا في السنة (t-1) ، فإنهم سوف يقللون إنتاجهم في السنة (t+1) وهكذا مما يقود الى النموذج العنكبوتي .

5- التخلف الزمني (Time Lags)

في تحليل إنحدار السلاسل الزمنية للمصروفات الإستهلاكية على الدخل من المعتاد أن نجد أن المصروفات الإستهلاكية في الفترة الحالية تعتمد من بين عناصر أخرى على المصروفات الإستهلاكية في الفترة السابقة بمعنى :

$$(6-10) u_t + \dots + \text{الإستهلاك في السنة } t-1 + b_3 + \text{الدخل في السنة } t + b_2 + b_1 = \text{الإستهلاك في السنة } t$$

إن إنحداراً مثل الموجود في المعادلة (6-10) يعرف بأنه إنحداراً ذاتياً

(Autoregression) وذلك أحد المتغيرات التوضيحية هو القيمة المتخلفة زمنياً

(Lagged Value) للمتغير المعتمد ، إن المنطق الذي يدعم هذا النموذج هو أن

المستهلكين لا يغيرون عاداتهم الإستهلاكية في الغالب لأسباب نفسية وتقنية

ومؤسسية ، فإذا أهملنا الحد المتخلف زمنياً في النموذج (3-10) فإن حد الخطأ

الناتج سوف يعكس نمطاً منتظماً بسبب تأثير الإستهلاك المتخلف على الإستهلاك الحالي (Current Consumption) .

6- معالجة البيانات (Manipulation of Data)

إن البيانات الخام عادة في التحليل التجريبي تتم معالجتها ، مثلاً في تحليلات الإنحدار للسلاسل الزمنية (Time-Series) التي تتضمن بيانات فصلية، وإن مثل هذه البيانات عادة تشتق من بيانات شهرية من خلال إضافة بيانات كل ثلاثة أشهر وتقسيم الناتج على ثلاثة ، إن هذه المعدلات تدخل تمهيداً (Smoothing) في البيانات من خلال طمس التقلبات (Fluctuations) في البيانات الشهرية ، في البيانات الفصلية تبدو أكثر اعتدالاً أو نعومة أو تمهيداً من البيانات الشهرية ، وإن هذه النعومة أو الاعتدال ربما يقود الى نمط منتظم في حدود الإضطراب وهذا يتضمن إدخالاً للارتباط الذاتي ، ثمة مصدر آخر لمعالجة البيانات وهو تحريف البيانات أو تقدير البيانات على أساس بيانات متوافرة (Extrapolation of data) مثلاً تعداد السكان يجري كل عشرة سنوات في بلد معين بحيث مثلاً يكون التعداد الأخير 1987 والسابق له هو تعداد 1977 والأسبق هو تعداد 1967 وقبله تعداد 1957 وهكذا ، والآن اذا كانت هناك حاجة للحصول على بيانات لعدد أو لبعض السنوات ضمن فترة متداخلة بين تعدادين مثلاً (1977-1987) فإن العملية الشائعة أن تحرف البيانات على أساس إفتراضات لأغراض محددة .

10-3 النتائج المترتبة على وجود مشكلة الارتباط الذاتي

(Consequence of Autocorrelation)

عندما يعاني حد الإضطراب (disturbance Term) من الارتباط المتسلسل أو الذاتي بين قيمه ، تحصل النتائج الآتية في حالة تطبيقنا لطريقة المربعات الصغرى الإعتيادية (OLS) :

- 1- إن قيمة المعلمات المقدرة تتأثر بوجود الارتباط الذاتي .
- 2- إن الأخطاء المعيارية للمعلمات المقدرة تتأثر أيضاً بوجود الارتباط الذاتي .
- 3- ولكن حتى لو كان الارتباط الذاتي موجوداً بين قيم المتغير العشوائي ، فإن تقديرات طريقة المربعات الصغرى الإعتيادية (OLS) للمعلمات لا تكون متميزة إحصائياً ، بمعنى إن القيمة المتوقعة تساوي المعلمة الحقيقية (True parameter) .
- 4- في حالة وجود الارتباط الذاتي في قيم حد الإضطراب فإن التباين المقدر بطريقة المربعات الصغرى (OLS) للمعلمات المقدرة يكون أكبر من التباين المقدر بالطرق الإقتصادية القياسية الأخرى .
- 5- في حالة وجود الارتباط الذاتي في قيم حد الإضطراب فإن تباين المتغير العشوائي (u_i) يكون تقديره قليلاً (Underestimated) على نحو خطير وهذه الخطورة تكون أكبر في حالة وجود ارتباط ذاتي موجب .
- 6- إذا كانت قيم المتغير العشوائي مرتبطة ذاتياً فإن التنبؤات (Predictions) الحاصلة على أساس تقديرات المربعات الصغرى الإعتيادية سوف تكون غير كفوءة بمعنى أنها تمتلك تباين أكبر من ذلك التباين المقدر بطرق قياسية أخرى .

4-10 إختبارات الارتباط الذاتي

- من الأمور المعروفة أن وجود الارتباط الذاتي ونمطه يمكن أن نصل إليه أو نحصل عليه من خلال رسم (plotting) بواقي الإنحدار ، أما مقابل قيمه المتخلفة أو الزمن .
- ولكن هناك ثمة إختبارات أكثر دقة للكشف عن مشكلة الارتباط الذاتي (Autocorrelation) ، من الإختبارات المطبقة تقليدياً إختبار معدل فون نيومن (Von Veumann) وإختبار دربن-واطسون (Durbin-Watson) :

وهذا الاختبار يمكن أن يأخذ الصيغة الآتية :

$$\frac{\delta^2}{S_x^2} = \frac{\sum_{t=2}^n (X_t - X_{t-1})^2 / (n-1)}{\sum (X - \bar{X})^2 / n}$$

وهذا هو نسبة تباين الفروقات الأولى (First-differences) لأي متغير مثل (X) على تباين (X). إن معدل فون نيومن يمكن تطبيقه للسلاسل الزمنية المشاهدة مباشرة وللمتغيرات العشوائية وهي المتغيرات التي تكون قيمتها المتتالية غير مرتبطة ذاتياً ، في حالة المتغير العشوائي (u) فإن قيمه غير قابلة للمشاهدة المباشرة ، ولكنها مقدرة عن طريق قيم البواقي الحاصلة من طريقة المربعات الصغرى الإعتيادية (OLS) (e'_s) ، وللعينات الكبيرة التي تكون مشاهداتها أكبر من ثلاثين مشاهدة (n أكبر من 30) فإن معدل فون نيومن ربما يكون كما يأتي :

$$\frac{\delta^2}{S_e} = \frac{\sum_{i=2}^n (\ell_t - \ell_{t-1})^2 / (n-1)}{\sum (\ell_t - \bar{\ell})^2 / n}$$

ويمكن ان يطبق تقريباً مع ($\bar{\ell} = 0$) بالتعريف ، ولكن ذلك غير ممكن لأن قيم بواقي (ℓ) طريقة المربعات الصغرى الإعتيادية (OLS) موزعة على نحو مستقل . لذلك فإن إختبار فون نيومن لا يمكن تطبيقه لإختبار الارتباط الذاتي لقيم المتغير العشوائي بخاصة اذا كانت العينة صغيرة أي أقل من ثلاثين مشاهدة (n أقل من ثلاثين) .

أما دربن وواطسن (Durbin-Watson) فقد إقترحا إختباراً يطبق في حالة العينات الصغيرة ، ولكن ذلك الإختبار ملائم فقط للإرتباط الذاتي من الدرجة الأولى (The First- Order autoregressive) ($u_t = \rho u_{t-1} + v_t$) وهذا الإختبار يأخذ الخطوات الآتية :

$$H_0 : \rho = 0$$

فرضية العدم

أو أن (H_0) : أن قيم (u) غير مرتبطة ببعضها ذاتياً ارتباطاً من الدرجة

الأولى ، إن هذه الفرضية تختبر ضد :

$$\neq 0$$

الفرضية البديلة : $H_1 : \rho$

أو أن (H_1) : أن قيم (u) مرتبطة ببعضها ذاتياً ارتباطاً من الدرجة الأولى .

لإختبار فرضية العدم نستخدم إحصاءة دربن-واطسون

: (Durbin-Watson statistic)

$$d = \frac{\sum_{t=2}^n (\ell_t - \ell_{t-1})^2}{\sum_{t=1}^n \ell_t^2}$$

إن قيم (d) تقع بين $(0)(4)$ ، وعندما تكون $(d=2)$ فإن $(\rho=0)$ ،

وهكذا فإن إختبار فرضية $(H_0 : \rho=0)$ يساوي إختبار فرضية $(H_0 : d = 2)$ ،

وعندما نوسع إحصاءة (d) نحصل على :

$$d = \frac{\sum_{t=2}^n (\ell_t - \ell_{t-1})^2}{\sum_{t=1}^n \ell_t^2} = \frac{\sum_{t=2}^n (\ell_t^2 + \ell_{t-1}^2 - 2\ell_t \ell_{t-1})}{\sum_{t=1}^n \ell_t^2}$$

$$d = \frac{\sum_{t=2}^n \ell_t^2 + \sum_{t=2}^n \ell_{t-1}^2 - 2 \sum_{t=2}^n \ell_t \ell_{t-1}}{\sum_{t=1}^n \ell_t^2}$$

ولكن في العينات الكبيرة فإن الصيغ :

$$\sum_{t=2}^n \ell_t^2 \quad \sum_{t=2}^n \ell_{t-1}^2 \quad \sum_{t=1}^n \ell_t$$

تقريباً متساوية ، ولذلك ربما يمكن ان تكتب الإحصاءة :

$$d \approx \frac{2\sum \ell_{t-1}^2}{\sum \ell_{t-1}^2} - \frac{2\sum \ell_t \ell_{t-1}}{\sum \ell_{t-1}^2}$$

$$d \approx \left(1 - \frac{\sum \ell_t \ell_{t-1}}{\sum \ell_{t-1}^2} \right)$$

ولكن :

$$\left(\frac{\sum \ell_t \ell_{t-1}}{\sum \ell_{t-1}^2} \right) = \hat{\rho}$$

ولذلك :

$$d \approx 2(1 - \hat{\rho})$$

ومن هذه الصيغة يبدو واضحاً أن قيم (d) تقع بين (0)(4) .

أولاً : اذا لم يكن هناك ارتباطاً ذاتياً ($\hat{\rho} = 0$) وإن ($d=2$) وهكذا اذا وجدنا من بيانات العينة أن (d^*) المحسوبة ($d^* \approx 2$) فإننا نقبل أنه ليس هناك ارتباطاً ذاتياً في الدالة .

ثانياً : اذا كان ($\hat{\rho} = +1$) فإن ($d=0$) ويكون لدينا ارتباطاً ذاتياً موجباً ، ولذلك اذا كانت ($0 < d^* < 2$) فإن هناك بعض درجات من الارتباط الذاتي الموجب ويكون ذلك الارتباط قوياً كلما إقتربت (d^*) من الصفر .

ثالثاً : اذا كانت ($\hat{\rho} = -1$) فإن ($d=4$) وعندئذ يكون لدينا ارتباطاً ذاتياً تاماً وسالباً ، ولذلك اذا كانت ($2 < d^* < 4$) فإن هناك درجة من الارتباط الذاتي السالب ويكون ذلك الارتباط أكثر قوة كلما إرتفعت قيمة (d^*) .

يجب أن يكون واضحاً أن إختبار دربن-واطسون يختبر فرضية العدم في عدم وجود ارتباط ذاتي ($\rho=0$) بصورة غير مباشرة من خلال إختبار فرضية مساوية للأولى تقول أن ($d=2$) .

الخطوة الأخرى ان يتم إستخدام بواقي العينة (ℓ_s') وحساب القيمة التجريبية لإحصاءة دربن-واطسون (d^*) ، وأخيراً فإن القيمة التجريبية لـ(d^*) يجب أن تقارن مع القيم النظرية لـ(d) تلك القيم لـ(d) التي تعرف المنطقة الحرجة للإختبار ، إن مشكلة هذا الإختبار هي أن التوزيع التام لـ(d) غير معروف ، ولكن دربن-واطسون كانا قد وضعاً حداً أعلى لـ(d_u)(d) وحداً أدنى لـ(d_L) لمستويات معنوية (d) الملائمة لإختبار فرضية عدم وجود الارتباط الذاتي من الدرجة الأولى ضد الفرضية البديلة في وجود الارتباط الذاتي الموجب من الدرجة الأولى ، لقد وضع دربن-واطسون جدولاً لتلك القيم العليا والقيم الدنيا عند مستوى (5% و 1%) من المعنوية ، وهذه الجداول يفترض أن تكون فيها قيم (u) إعتيادية ومتجانسة وغير مرتبطة ذاتياً .

إن الإختبار ذاته يقارن القيمة التجريبية (d^*) المحسوبة من بواقي الإنحدار مع الحد الأدنى (d_L) والحد الأعلى (d_u) في جداول دربن-واطسون وقيمتها المحولة ($4-d_L$) ($4-d_u$) ، إن المقارنة بإستخدام (d_L) (d_u) تبحث إمكانية وجود ارتباطاً ذاتياً موجباً ومقارنة مع ($4-d_L$) ($4-d_u$) تبحث إمكانية وجود ارتباطاً ذاتياً سالباً :

1- إذا كانت (d^*) المحسوبة أقل من (d_L) النظرية فإننا نرفض فرضية العدم التي تنص على عدم وجود ارتباط ذاتي ، نقبل أن هناك ارتباطاً ذاتياً موجباً من الدرجة الأولى .

2- إذا كانت (d^*) المحسوبة أكبر من ($4-d_L$) فإننا نرفض فرضية العدم التي تنص على عدم وجود الارتباط الذاتي ونقبل أن هناك ارتباطاً ذاتياً سالباً من الدرجة الأولى .

- 3- إذا كانت $(d_4 < d^* < (4-d_4))$ فإننا نقبل فرضية العدم التي تنص على عدم وجود الارتباط الذاتي .
- 4- إذا كانت $(d_L < d^* < d_4)$ أو إذا كانت $(d^* < (4-d_L) < (4-d_4))$ فإن الاختبار يكون غير حاسم .

10-5 بعض النواقص في اختبار درين - واطسون

أولاً : إن الإحصاءة (d) تعد مقياساً غير ملائم للارتباط الذاتي إذا كان هناك بين المتغيرات التوضيحية قيماً متخلفة زمنياً (Lagged Values) لمتغير داخلي .

ثانياً : إن مدى قيم (d) التي تغطي مساحة منطقة عدم الحسم $(d_L < d^* < d_4)$ و $(4-d_L) < d^* < (4-d_4)$ تشكل عشرة في طريق تطبيق اختبار درين - واطسون .

ثالثاً : إن اختبار درين- واطسون غير ملائم لاختبار درجات أعلى للارتباط المتسلسل ، أو لأشكال أخرى من الارتباط الذاتي مثلاً الارتباط الذاتي المتسلسل في الأشكال غير الخطية لقيم (u_t) .

10-6 الحلول لمشكلة الارتباط الذاتي

إن الحل الملائم المعتمد أو الذي يتم إختياره لحالة ارتباط ذاتي معينة يعتمد أساساً على مصدر (Source) الارتباط الذاتي ، وهكذا إذا كان مصدر الارتباط الذاتي هو متغيرات محذوفة فإن الإجراء الملائم هو إدخال تلك المتغيرات ضمن منظومة أو مجموعة المتغيرات التوضيحية .

من الممكن أن نوضح حدوث حالة شبه ارتباط ذاتي (quasi-auto correlation) مع التأثير الراجع في دالة الإستهلاك ، فالإستهلاك في الفترة الزمنية (t) يعتمد ليس فقط على الدخل الحالي

(Current Income) (X_t) وإنما أيضاً على مستوى الخل في الفترات الزمنية السابقة ، يمكن كتابة هذا النمط من دالة الإستهلاك بأبسط شكل من أشكالها كما يأتي :

$$C_t = b_0 + b_1X_t + b_2X_{t-1} + u_t$$

فإذا حذف متغير الدخل المتخلف فترة زمنية واحدة فإن تأثيره سوف ينعكس في قيم المتغير العشوائي (u_t) وربما أيضاً في معلمة متغير الدخل الحالي ، والتي ستكون معلمة متحيزة .

إن الارتباط الذاتي سوف يحذف أو ينتهي في هذه الحالة من خلال إدخال متغير الدخل المتخلف زمنياً في الدالة بوصفه متغيراً توضيحياً للإستهلاك الحالي (Current Consumption) ، ومن أبسط الطرق لمعرفة في ما اذا كان الارتباط الذاتي بسبب حذف متغيرات هو أن نقوم بتحليل إنحدار البواقي (residuals) (ℓ_s) على المتغيرات التي تعد متغيرات توضيحية ملائمة على أسس نظرية مسبقة للظاهرة قيد الدراسة .

بالطريقة نفسها اذا كان مصدر الارتباط هو التحديد الرياضي غير الملائم للعلاقة ، فإن المعالجة تتم بتغيير الشكل الخطي الأولي وهذا يمكن أن يبحث بوساطة تحليل إنحدار البواقي على درجات قوة أعلى للمتغيرات التوضيحية أو الحساب في علاقة خطية باللوغاريتم .

الفصل الحادي عشر
مشكلة عدم ثبات التباين

مشكلة عدم ثبات التباين

1-11 مقدمة (Heteroscedasticity Problem)

من الإفتراضات المهمة المتعلقة بالمتغير العشوائي (u) هو ان إحتماالية توزيع للمتغير العشوائي تبقى نفسها عبر كل مشاهدات (X)، وبخاصة فإن تباين كل (u_i) نفسه لكل قيم المتغير المستقل، وبالرموز لدينا :

$$\begin{aligned} \text{Var}(u) &= E\{(u_i - E(u))\}^2 \\ &= E(u_i)^2 = \delta_u^2 \end{aligned} \quad \text{ثابت}$$

إن هذا الإفتراض يعرف بوصفه إفتراض الثبات أو التجانس أو إفتراض ثبات تباين الـ (u_s) ، فإذا لم يتحقق في أية حالة خاصة فإننا نقول أن (u_s) هي غير متجانسة (Heteroscedasticity) :

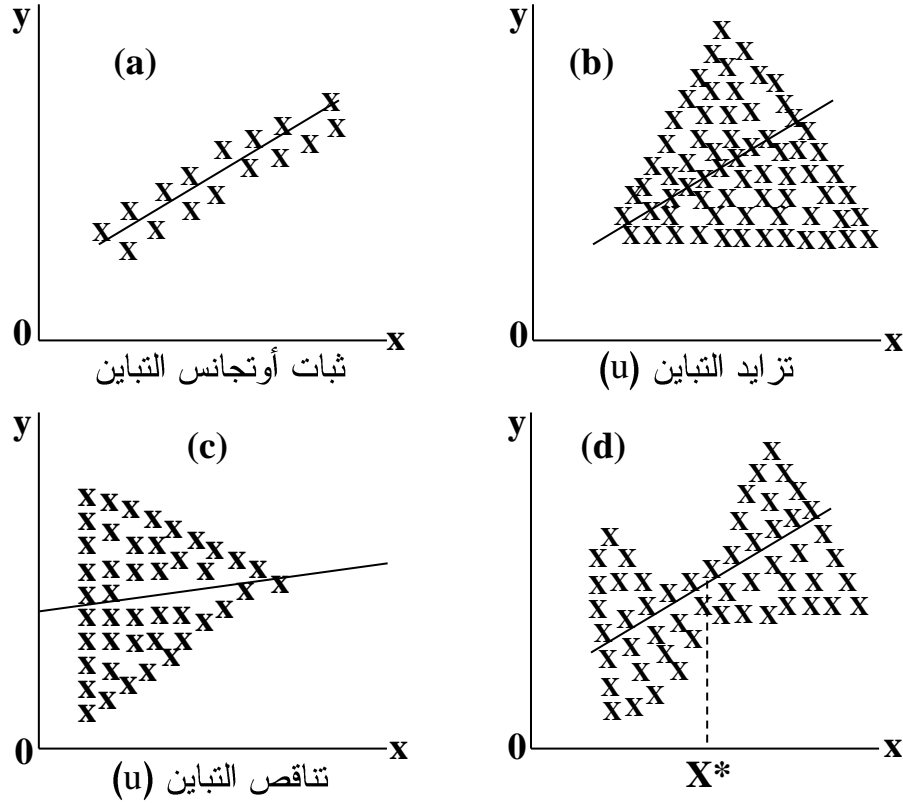
$$\text{Var}(u_i) = \delta_{ui}^2 \quad \text{غير ثابت}$$

2-11 التفسير والعرض بصيغة شكل الانتشار لثبات وعدم ثبات التباين

إن معنى إفتراض ثبات التباين هو أن إنحراف (Variation) كل (u_i) حول وسطه الحسابي المساوي للصفر لا يعتمد على قيمة (X)، إن تباين كل (u_i) يبقى نفسه بغض النظر عن القيم الصغيرة والقيم الكبيرة للمتغير المستقل .
إن (δ_u²) ليس دالة في (X_i) ، وهذا يعني :

$$\delta_u^2 \neq f(X_i)$$

وفي شكل الانتشار فإن تجانس التباين (Homoscedasticity) يمكن أن يوضح من الانتشار العشوائي (u_s) ضمن مسافة ثابتة (Constant Distance) حول خط الانحدار :



شكل (1-11) ثبات وعدم التباين

فإذا كان (δ_u^2) غير ثابت ولكن قيمه (its values) تعتمد على قيم (X) فإننا ربما نكتب ذلك بالصيغة الآتية :

$$\delta_u^2 = f(X)$$

إن حالة عدم ثبات أو عدم تجانس التباين ((Heteroscedasticity)) تبدو أو تتوضح من خلال تزايد أو تناقص إنتشار (dispersion) المشاهدات عن خط الإنحدار ، إن نمط المشاهدات على شكل الإنتشار يعتمد على شكل عدم الثبات أو عدم التجانس للتباين بمعنى يعتمد على شكل العلاقة بين (δ_u^2) و (X_i) .

ثمة ثلاثة أشكال لحالة عدم تجانس التباين في الشكل (1-11) ففي الشكل (b 1-11) تم تصوير حالة تزايد تباين الـ $(u's)$ فكلما ازداد (X) يزداد

تباين (u) ، وهذا يمثل حالة عدم ثبات أو عدم تجانس التباين شائعة في التطبيقات الإقتصادية القياسية ، في الشكل (1-11 c) نبين نمط تناقص عدم التجانس للتباين ، فكلما أخذ (X) قيمة أكبر فإن إنحراف المشاهدات عن خط الانحدار يتناقص أو يصغر ، بمعنى إن تباين المتغير العشوائي يتغير بالاتجاه المعاكس مع المتغير التوضيحي ، وأخيراً في الشكل (1-11 d) رسمنا الحالة الأكثر تعقيداً من حالات عدم تجانس التباين وهي أن تباين المتغير العشوائي (u) يتناقص في البداية كلما أخذ المتغير التوضيحي (X) قيمة أكبر ، ولكن بعد مستوى معين لـ (X) مثلاً (X^*) فإن تباين (u) يزداد مع زيادة المتغير (X) ، يجب أن يكون واضحاً إن نمط عدم تجانس التباين يعتمد على إشارات وقيم معاملات العلاقة : ($\delta^2 = f(X_i)$) طالما أن (u_i) هي قيم غير ممكن مشاهدتها فإننا لانعرف النمط الحقيقي لعدم تجانس التباين ، ولكن في البحوث الطبيعية فإن المختصين بالإقتصاد القياسي عادةً يضعون الافتراض الملائم إن عدم تجانس التباين هو بشكل :

$$\delta_{ui}^2 = K^2 X^2$$

عندما يكون (K) ثابت ويمكن أن يقدر من النموذج .

11-3 إمكانية وجود افتراض تجانس التباين

في تطبيقات إقتصادية قياسية عدة فإن افتراض ثبات التباين للمتغير العشوائي ربما يتوقع ان لا يحدث أو ربما يكون غير موجود ، وهنا يمكن فهمه بسهولة اذا أخذنا بنظر الاعتبار العناصر التي يتم إمتصاص آثارها بوساطة حد الإضطراب (Disturbance Term) أو المتغير العشوائي ، قلنا سابقاً أن (u) يعبر عن التأثير على المتغير المعتمد من قبل الإخطاء في قياس المتغير المعتمد والمتغيرات المحذوفة ، وعلى كلا الجانبين هناك أسباب للتوقع أن تباين المتغير

العشوائي يختلف عبر الزمن أو يختلف على نحو منتظم مع المتغير التوضيحي (X) في معظم الحالات . وهكذا إذا ازداد (Y) فإن أخطاء القياس (Error of Measurment) تميل الى الزيادة أيضاً وذلك لأنه يصبح من الصعوبة جمع بيانات وتدقيق إتساق تلك البيانات ودرجة الوثوق بها ، والأكثر من ذلك فإن أخطاء القياس تميل الى التراكم عبر الزمن ، بحيث أن حجمها يزداد ، وفي هذه الحالة فإن تباين المتغير العشوائي يزداد مع زيادة قيم المتغير المستقل أو التوضيحي (X) . ومن ناحية أخرى فإن أساليب أخذ العينات والطرق المختلفة في جمع البيانات في تطور مستمر وهكذا فإن أخطاء القياس ربما تتناقص وفي هذه الحالة فإن (δ^2) يتناقص عبر الزمن . والأكثر أهمية من كل هذا هو أن متغيرات محذوفة من الدالة عدة تميل الى التتغير بالإتجاه نفسه مع (X) المتغير التوضيحي ، وهكذا مسببة زيادة في الإنحراف (Variation) في المشاهدات عن خط الإنحدار .

مثلاً : إفتراض أن لدينا عينة مقطوع عرضي (A Crossection Sample) لميزانيات العوائل والتي منها نريد أن نقيس دالة الإدخار (Saving Function) :

$$S_i = b_0 + b_1 Y_i + U_i$$

عندما يكون :

$$S_i = \text{إدخارات العوائل}.$$

$$Y_i = \text{دخل العوائل} .$$

في هذه الحالة فإن إفتراض ثبات تباين المتغير العشوائي (u) غير ملائم وذلك لأن العوائل ذات المستوى العالي من الدخل تعرض إختلافات أكبر كثيراً في سلوكها الخاص بالإدخارات من العوائل ذات الدخل المنخفض ، فالعوائل ذات الدخل العالي تميل الى الإلتصاق بمستوى معين من المعيشة وعندما ينخفض دخلها تقوم بالإستقطاع من الإدخارات وليس من الإنفاق الإستهلاكي

لهم، بينما العوائل ذات الدخل المنخفض تدخر لأغراض معينة ، وهكذا فإن نمط إدخاراتهم أكثر إنتظاماً . وهذا يتضمن أنه عند المستويات العالية من الدخل ، فإن (u_i) سيكون عالياً بينما عند المستويات المنخفضة للدخل فإن (u_i) سيكون صغيراً ، ولذلك فإن إفتراض ثبات أو تجانس تباين (u_i) سيكون غير موجود ، عندما تقدر دالة الإدخارات من المقاطع العرضية لميزانية الأسرة .

ثمة مثلاً آخر اذا أخذنا عينة مقطع عرضي من شركات في صناعة معينة من أجل إستخدامها لتقدير دالة إنتاج بصيغة كوب - دوغلاس (Cobb-Douglas) :

$$X = b_0 \cdot L^{b_1} \cdot K^{b_2} \cdot u$$

إن (u) في هذه الحالة يمتص تأثير الاختلافات التكنولوجية لمختلف الشركات وكذلك تأثير الاختلافات في المهارات والتنظيم بين الشركات وعناصر أخرى ، إن هذه العناصر لا تتغير على نحو كبير في الشركات الصغيرة ، بينما من المتوقع أن تتغير (Vary) في الشركات الكبيرة ، ولذلك فإن قيم (u) سوف لا تتجانس (Heteroscedastic) .

وخلاصة القول ان هناك وعلى أسس مسبقة أسباب للإعتقاد بأن إفتراض تجانس تباين المتغير العشوائي ربما في مناسبات عديدة يتم مخالفته في التطبيق . ولذلك يصبح من المهم جداً أن نتفحص ما يترتب على وجود حالة عدم تجانس أو عدم ثبات تباين المتغير العشوائي وتأثيرها على المعلمات المقدرة وعلى الإنحرافات المعيارية لتلك المعلمات .

11-4 النتائج المترتبة على وجود مشكلة عدم تجانس أو عدم ثبات تباين

المتغير العشوائي (u)

إذا لم يتحقق شرط أو إفتراض تجانس تباين المتغير العشوائي فإننا نتوقع أن يكون لدينا المترتبات (Consequences) الآتية :

- 1- أن لا نستطيع تطبيق قوانين التباينات للمعلمات من أجل إجراء إختبارات المعنوية الإحصائية وبناء حدود الثقة للمعلمات .
- 2- اذا كانت قيم (u) غير ثابتة التباين أو غير متجانسة التباين ، فإن المعلمات المقدرة بطريقة المربعات الصغرى الإعتيادية ليس لها صفة أقل تباين في صنف المعلمات المقدرة غير المتحيزة بمعنى أن تلك المعلمات غير كفوءة في العينات الصغيرة وفي العينات الكبيرة .
- 3- إن المعلمات المقدرة سوف تبقى غير متحيزة إحصائياً ، بمعنى أنه حتى لو أنه تباين (u) غير ثابت أو غير متجانس فإن المعلمات المقدرة (\hat{b}_i) سوف لن يكون لها تحيزاً إحصائياً ، أي إن القيمة سوف تساوي المعلمات الحقيقية :

$$E(\hat{b}_i) = b_i$$

- 4- إن التنبوء بقيم (Y) لقيمة معينة من (X) المعتمدة أو المتأسسة على المعلمات المقدرة (\hat{b}_s) من البيانات الأصلية ، وذلك لأن لها تباين عالي ، بمعنى ان التنبوء يتضمن تباينات (Variances) المتغير العشوائي وتباينات المعلمات المقدرة والتي هي ليست صغرى بسبب حدوث عدم تجانس التباين .

5-11 إختبارات ثبات أو عدم تجانس التباين

- لقد إقترحت إختبارات مختلفة للكشف عن عدم تجانس التباين ، ثمة إختبارين أساسيين وهما الأبسط في التطبيق .

1-5-11 إختبار إرتباط الرتب لسيبرمان

The Spearman Rank-Correlation Test

- هذا هو أبسط الإختبارات التي يمكن أن تطبق أما الى العينة الصغيرة أو الكبيرة ويمكن ان نضعه بالخطوات الآتية :

الخطوة الأولى : نقوم بإنحدار (Y) على (X) من خلال تقدير المعادلة الإحتمالية الآتية :

$$\hat{Y}_i = \hat{b}_0 + \hat{b}_1 X_i + u_i$$

ونحصل على البواقي (residuals) (ℓ'_s) وهي تقديرات لقيم المتغير العشوائي (u) .

الخطوة الثانية : نرتب البواقي (ℓ) (مع إهمال الإشارة المرافقة لها) ونرتب كذلك قيم المتغير التوضيحي إما تنازلياً أو تصاعدياً و ثم نحسب معامل ارتباط الرتب :

$$r_{e.x}^1 = 1 - \frac{6 \sum D^2}{n(n^2 - 1)}$$

عندما يكون :

$$D_i = \text{الفرق بين الرتب المعطاة لكل زوج من (x و e) .}$$

$$n = \text{عدد المشاهدات في العينة الإحصائية .}$$

إن القيمة العالية لمعامل الرتب (r^1) تقترح وجود مشكلة عدم تجانس التباين ، إذا كان لدينا علاقة مع متغيرات توضيحية عدة فعلينا أن نحسب معامل ارتباط الرتب بين (ℓ_i) وكل واحد من تلك المتغيرات التوضيحية على نحو منفصل .

11-5-2 اختبار كولدفيلد وكوانت (The Goldfeld and Quandt Test)*

إن هذا الاختبار يطبق في حالة العينات الكبيرة والمشاهدات يجب أن يكون عددها على الأقل ضعف عدد المعلمات المطلوب تقديرها في الدالة ، والاختبار يفترض التوزيع الطبيعي (Normality) وعدم الارتباط المتسلسل لقيم (u) ، والفرضية التي تختبر هذا الاختبار هي :

* S.M Goldfeld and R.E Quadts , "Some Tests For Homoscedasticity" Journa of American Statistical Association ,Vo 160 , 1965 , PP.539-47)

أ- فرضية العدم (Null Hypothesis)

إن قيم تباين المتغير العشوائي متجانسة أو ثابتة ($H_0 : U_i's$)

ب- الفرضية البديلة (Alternative Hypothesis)

إن قيم تباين المتغير العشوائي غير متجانسة ($H_1 : U_i's$)

(مع تزايد التباين)

أما خطوات هذا الاختبار فهي كما يأتي :

الخطوة الأولى : نرتب المشاهدات إستناداً الى حجم المتغير التوضيحي

(X)

الخطوة الثانية : نختار عشوائياً أو إعتباطياً (Arbitrarily) عدداً معيناً

(C) من المشاهدات المركزية والتي نحذفها من التحليل ، لقد وجد من بعض

التجارب التي قام بها كولدفيلد وكونت أنه بالنسبة للعينات أكبر من (30)

مشاهدة فإن العدد المثالي من المشاهدات المركزية التي يجب أن تحذف من

الاختبار هي تقريباً ربع عدد المشاهدات الكلية مثلاً (8) بالنسبة الى (n=30) و

(16) بالنسبة الى (n=60) ، والمشاهدات المتبقية (n-c) الى عينتين متساويتين

في الحجم $(\frac{n-c}{2})$ أحدهما تتضمن القيم الصغيرة للمتغير التوضيحي (X)

والأخرى تتضمن القيم الكبيرة للمتغير التوضيحي (X) .

الخطوة الثالثة : نقدر الإنحدار لكل عينة فرعية ، ونحصل على مجموع

تربيع البواقي من واحدة منها :

البواقي من العينة مع القيم المنخفضة لـ (X) $(\sum \ell_1^2)$ مع درجات حرية

$(\left[\frac{n-c}{2} \right] - K)$ عندما يكون (K) العدد الكلي للمعلمات في النموذج .

البواقي من العينة الفرعية مع القيم العالية لـ (X) $(\sum \ell_2^2)$ مع درجات حرية

$(\left[\frac{n-c}{2} \right] - K)$ عندما يكون (K) العدد الكلي للمعلمات في النموذج .

وإذا قسمنا كل واحد من مجموعات تربيع البواقي أو تربيع الانحرافات على درجات الحرية الملائمة نحصل على تقديرات لتباينات (u_s) المتغير العشوائي في العينتين الإحصائيتين ، وإن نسبة هذين التباينين تكون كما يأتي :

$$F^* = \frac{\frac{\sum \ell_2^2}{\left(\frac{n-c}{2}\right) - K}}{\frac{\sum \ell_1^2}{\left(\frac{n-c}{2}\right) - K}} = \frac{\sum \ell_2^2}{\sum \ell_1^2}$$

يكون لها توزيع (F) مع درجات حرية :

$$v_1 = v_2 = \left[\left(\frac{n-c}{2} \right) - K \right] = \left[\frac{(n-c-2K)}{2} \right]$$

عندما يكون :

n = عدد المشاهدات

c = المشاهدات المركزية المحذوفة

K = عدد المعلمات المقدرة من كل إحداهما

فإذا كان التباينين متساويين أو متشابهين ، بمعنى أن تباين المتغير العشوائي (u) متجانس (Homoscedastic) أو ثابت ، فإن قيمة (F^*) سوف تميل الى (1) ، فإذا اختلفت التباينات ، فإن قيمة (F^*) ستكون له قيمة أكبر (إذا علمنا أن تصميم الاختبار يتضمن أن ($\sum \ell_2^2$) أكبر من ($\sum \ell_1^2$)) ، نقارن القيمة المشاهدة لـ (F^*) مع القيمة النظرية (F) مع درجات حرية ($v_1 = v_2 = \left[\frac{(n-c-2K)}{2} \right]$) عند مستوى معنوية مختار ، والقيمة النظرية لـ (F) نحصل عليها من الجدول (F) .

فإذا كان :

(F*) أصغر من (F) الجدولية ، فإننا نقبل أن تباين المتغير العشوائي (u) متجانس ، وكلما كانت قيمة (F*) المشاهدة (نسبة التباين الثاني الى التباين الأول) أكبر فإن عدم تجانس التباين يكون أقوى في المتغير العشوائي .

11-6 الحل لمشكلة عدم ثبات التباين

إذا تم إثبات وجود مشكلة عدم تجانس التباين من خلال أو على أساس أي من الإختبارات ، فإن الحل الملائم هو تحويل النموذج الأصلي بطريقة للحصول على شكل نموذج يكون فيه حد الإضطراب المحول أو المتغير العشوائي المحول بتباين ثابت .

وبعد ذلك يمكن أن نطبق طريقة المربعات الصغرى الكلاسيكية على النموذج المحول ، إن النموذج بصيغة التحويل يصغر أو يقلل الى التعديلات على البيانات الأصلية ، وهذا التعديل على النموذج يعتمد على الشكل الخاص من تجانس التباين ، بمعنى أن ذلك يعتمد على شكل العلاقة بين تباين المتغير العشوائي (δ_u^2) وقيم المتغير التوضيحي أو المتغيرات التوضيحية .

$$\delta_u^2 = f(X_i)$$

وعموماً فإن تحول النموذج الأصلي (Transformation) يتكون من تقسيم العلاقة الأصلية على الجذر التربيعي للحد أو الصيغة المسؤولة عن تجانس التباين ، ولتوضيح هذه العبارة بأمثلة : إفتراض إن النموذج الأصلي هو:

$$\hat{Y}_i = \hat{b}_0 + \hat{b}_1 X_i + u_i$$

يكون فيه (u_i) غير ثابت أو غير متجانس التباين ، ولكنه يفرض

(Satisfies) بقية الإفتراضات الإحصائية لنموذج الإنحدار الخطي .

الحالة الأولى : إفتراض إن عدم تجانس التباين هو بصيغة :

$$E(U_i)^2 = \delta_{ui}^2 = K^2 X^2$$

عندما يكون (K) ثابت نهائي يتم تقديره مع النموذج) ، بمعنى أن تباين

(u) يزداد نسبياً مع (X^2) . ونحل من أجل الحصول على قيمة (X^2) يكون لدينا :

$$K^2 = \frac{\delta_{ui}^2}{X^2}$$

وهذا يقترح أن التحول الملائم من النموذج الأصلي هو تقسيم العلاقة

الأصلية على : $(\sqrt{X^2} = X)$

والذي يعني أن صيغة التحول الملائمة هي :

$$\frac{Y_i}{X_i} = \frac{b_0}{X_i} + b_1 + \frac{u_i}{X_i}$$

إن المتغير العشوائي المحول الجديد $(\frac{u_i}{X_i})$ هو بتباين متجانس طالما

أن :

$$E\left(\frac{u_i}{X_i}\right)^2 = \frac{1}{X_i^2} E(U_i)^2 = \frac{1}{X_i^2} \delta_{ui}^2$$

الحالة الثانية : إفتراض أن شكل عدم التجانس هو :

$$E(U_i)^2 = \delta_{ui}^2 = K^2 X$$

إن التحول الملائم للنموذج الأصلي يتألف من تقسيم العلاقة الأصلية

على $(\sqrt{X^2})$:

$$\begin{aligned} \frac{Y}{\sqrt{X}} &= \frac{b_0}{\sqrt{X}} + b_1 \frac{X}{\sqrt{X}} + \frac{u}{\sqrt{X}} \\ (YX^{-\frac{1}{2}}) &= b_0 X^{-\frac{1}{2}} + b_1 X^{\frac{1}{2}} + \frac{u}{\sqrt{X}} \end{aligned}$$

إن المتغير العشوائي أو الحد العشوائي المحول $(\frac{u_i}{\sqrt{X}})$ هو متجانس

التباين (Homoscedastic) ، مع تباين ثابت $= (K^2)$.

مثال : متوسط الأجور (Y) وعدد العاملين (X) في (30) شركة وتم

إجراء إنحدار (Y) على (X) للعينة كلها نحصل :

$$\hat{Y} = 7.5 + 0.009X \quad R^2 = 0.90$$

$$(40.27) \quad (16.10)$$

نتائج أنحدار (Y) على (X) للاثنتي عشرة مشاهدة الأولى :

$$\hat{Y} = 8.1 + 0.006X \quad R^2 = 0.66$$

$$(39.4) \quad (4.36) \quad \text{Ess}_1 = 0.507$$

نتائج أنحدار (Y) على (X) للاثنتي عشرة مشاهدة الثانية :

$$\hat{Y} = 6.1 + 0.013X \quad R^2 = 0.60$$

$$(4.16) \quad (3.89) \quad \text{Ess}_2 = 3.9095$$

$$\text{Ess} = \sum \ell_i^2$$

وحيث أن :

$$F^* = \frac{\text{Ess}_2}{\text{Ess}_1} = \frac{3.9095}{0.507}$$

$$= 6.10$$

وهذه القيمة أكبر من (F) النظرية أو الجدولية عند درجات حرية

$(v_1 = 10)$ و $(v_2 = 10)$ هي (2.97) ، إذاً نقبل فرضية العدم ، إن المتغير

العشوائي غير متجانس التباين .

الفصل الثاني عشر
أسلوب المصفوفات في
تحليل الإنحدار

أسلوب المصفوفات في تحليل الانحدار

1-12 مقدمة

إن جبر المصفوفات يستعمل على نحو متزايد في التحليل الرياضي الإحصائي . إن أسلوب المصفوفات يعد ضرورة عملية في تحليل الانحدار المتعدد طالما أنه يسمح بأنظمة معادلات واسعة وأعداد كبيرة من البيانات . وفي هذا الفصل فإننا سنقوم أولاً بدراسة مختصرة لمقدمة في جبر المصفوفات (Matrix Algebra) ، وبعد ذلك نطبق طرق المصفوفات على نموذج الانحدار الخطي البسيط ، ولكن لا بد من التأكيد أن جبر المصفوفات غير ضروري جداً في تحليل الانحدار البسيط مع متغير توضيحي واحد ، ولكنه يوفر في حالة استخدامه هنا أساساً جيداً لفهم تطبيق جبر المصفوفات على حالات الانحدار المتعدد (Multiple Regression) .

2-12 المصفوفات (Matrices)

1-2-12 تعريف المصفوفة

تعرف المصفوفة بوصفها عبارة عن مستطيل لنظام من العناصر مرتبة بصيغة صفوف (rows) وأعمدة (Columns) .

مثال على المصفوفة :

الصف الأول	6000	23
الصف الثاني	13000	47
الصف الثالث	11000	35
العمود الأول		العمود الثاني

إن عناصر (Elements) هذه المصفوفة المعينة هي أرقام تعبر عن الدخل (العمود الأول) والعمر (العمود الثاني) لثلاثة أشخاص ، إن عناصر المصفوفة مرتبة بصف (الشخص) وعمود (صفة الشخص) ، وهكذا فإن العنصر في الصف الأول والعمود الأول (6000) يمثل دخل الشخص الأول ، والعنصر في الصف الأول وفي العمود الثاني (23) يعبر عن عمر الشخص الأول . إن بُعد (Dimension) المصفوفة هو (2×3) وهذا يعني ثلاثة صفوف مع عمودين ، فإذا اردنا أن نعرض الدخل والعمر لألف (1000) شخص بصيغة مصفوفة كما عبرنا عن ذلك فنحن سوف نحتاج الى مصفوفة (2×1000) .

أمثلة أخرى على المصفوفات :

$$\begin{pmatrix} 1 & 0 \\ 2 & 10 \end{pmatrix} \begin{pmatrix} 4 & 7 & 12 & 16 \\ 3 & 15 & 9 & 8 \end{pmatrix}$$

إن هاتين المصفوفتين لهما بُعد (2×2) و (4×2) ، يجب أن نلاحظ أننا دائماً نحدد رقم الصفوف أولاً ثم بعد ذلك نحدد رقم الأعمدة في حالة إعطاء أبعاد المصفوفات . وكما هي الحال في الجبر الإعتيادي ربما نستعمل رموزاً للتعريف بعناصر المصفوفة :

$$\begin{matrix} & \begin{matrix} J = 1 & J = 2 & J = 3 \end{matrix} \\ \begin{matrix} i = 1 \\ i = 2 \end{matrix} & \begin{pmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \end{pmatrix} \end{matrix}$$

لاحظ أن الأرقام المرافقة للحرف (a) يكون الرقم الأول من اليسار يمثل الصف الأول والرقم الثاني من اليسار يمثل العمود ، يجب أن نستعمل الرمز (a_{ij}) للعنصر في (i^{th}) صف وفي (j^{th}) عمود ، وفي مثالنا أعلاه فإن : $(i=1,2)$ و $(j=1,2,3)$.

وربما يشار الى المصفوفة برمز مثل A , X , Z وهكذا فإننا يمكن أن نعرف المصفوفة السابقة كما يأتي :

$$A = \begin{pmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \end{pmatrix}$$

إن الإشارة الى المصفوفة (A) عندئذ يتضمن الإشارة الى نظام من (3×2) ، ثمة رمز آخر للمصفوفة (A) السابقة هو :

$$A = [a_{ij}] \quad (i=1,2) \text{ و } (j=1,2,3)$$

وبهذه الطريقة نتجنب الحاجة الى كتابة كل عناصر المصفوفة من خلال كتابة العنصر العام فقط ، إن هذا الترميز يمكن أن يستعمل فقط عندما تكون العناصر رموزاً (Symbols) . لنلخص الموضوع فنقول أن مصفوفة مع (r) من الصفوف و (c) من الأعمدة سوف تعرض أما بصيغتها الكاملة :

$$A = \begin{pmatrix} a_{11} & a_{12} & a_{1j} & a_{1c} \\ a_{21} & a_{22} & a_{2j} & a_{2c} \\ a_{i1} & a_{i2} & a_{ij} & a_{ic} \\ a_{r1} & a_{r2} & a_{rj} & a_{rc} \end{pmatrix}$$

أو بالصيغة المختصرة :

$$A = [a_{ij}] \quad (i=1,2,\dots,r) \text{ و } (j=1,2,\dots,c)$$

بعض الملحوظات :

1- لا يمكن أن تعتقد أن المصفوفة هي رقم ، إنها منظومة (a set) من العناصر رتبت في نظام ، فقط في حالة المصفوفة ، ذات البعد الواحد (1×1) هناك رقم منفرد في المصفوفة .

2- إن الصيغة الآتية لا تمثل مصفوفة :

$$\begin{pmatrix} 14 \\ 8 \\ 10 & 15 \\ 9 & 16 \end{pmatrix}$$

طالما ان الأرقام لم ترتب بصيغة أعمدة وصفوف .

2-2-12 المصفوفة مربعة الأبعاد (Square Matrix)

يقال للمصفوفة مربعة (Square) إذا كان عدد الصفوف (rows)

يساوي عدد الأعمدة (columns) ، وهذين مثالين :

$$\begin{pmatrix} 4 & 7 \\ 3 & 9 \end{pmatrix} \quad \begin{pmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{pmatrix}$$

3-2-12 المتجه (Vector)

وهو مصفوفة تحتوي على عمود واحد فقط وتدعى عمود متجه

(Column Cector) أو متجه (Vector) وهذين مثالين :

$$A = \begin{pmatrix} 4 \\ 7 \\ 10 \end{pmatrix} \quad C = \begin{pmatrix} C_1 \\ C_2 \\ C_3 \\ C_4 \\ C_5 \end{pmatrix}$$

إن المتجه (A) هو مصفوفة (3×1) والمتجه (C) هو مصفوفة (5×1)
 إن مصفوفة تحتوي على صف واحد فقط تدعى متجه صف (row vector)
 وهنا مثالين أيضاً :

$$B^1 = \begin{bmatrix} 15 & 25 & 50 \end{bmatrix} \quad D^1 = \begin{bmatrix} C1 & C2 \end{bmatrix}$$

يجب أن نلاحظ أن متجه صف (B^1) (row vector B^1) هو مصفوفة
 (3×1) ومتجه صف (D^1) (row vector D^1) هو مصفوفة (2×1) .

4-2-12 مقلوب المصفوفة (Transpose)

إن مقلوب المصفوفة (Transpose) لمصفوفة (A) هي مصفوفة أخرى
 تدعى (A^1) نحصل عليها بوساطة جعل الأعمدة صفوفاً والصفوف أعمدة
 للمصفوفة (A) .

مثال : إذا كان لدينا المصفوفة (A) :

$$A = \begin{pmatrix} 2 & 5 \\ 7 & 10 \\ 3 & 4 \end{pmatrix} \quad (2 \times 3)$$

بعد ذلك فإن المقلوبة (Transpose) لهذه المصفوفة هي :

$$A^1 = \begin{pmatrix} 2 & 7 & 3 \\ 5 & 10 & 4 \end{pmatrix} \quad (2 \times 3)$$

لاحظ أن العمود الأول للمصفوفة (A) هو الصف الأول للمقلوبة (A^1)
 وكذلك فإن العمود الثاني للمصفوفة (A) هو الصف الثاني للمقلوبة (A^1) .
 بالمقابل فإن الصف الأول من المصفوفة (A) أصبح العمود الأول للمقلوبة

(A¹) وهكذا ، لاحظ أن أبعاد المصفوفة (A) مؤشر بالأرقام تحت الحرف (A) إن هذه الأبعاد تنعكس في حالة (A¹) .
مثال آخر :

$$C = \begin{pmatrix} 4 \\ 7 \\ 10 \end{pmatrix}_{(3 \times 1)} \quad C^1 = \begin{pmatrix} 4 & 7 & 10 \end{pmatrix}_{(3 \times 1)}$$

وهكذا فإن المقلوبة (Transpose) لمتجه عمود هي متجه صف ،
والعكس بالعكس ، وهذا هو السبب الذي جعلنا نستخدم الرمز (B¹) للتعبير عن
متجه صف طالما ان من الممكن أن يعبر ذلك عن المقلوبة لمتجه عمود (B) ،
وعلى نحو عام لدينا :

$$A = \begin{pmatrix} a_{11} & \dots & a_{1c} \\ \vdots & & \vdots \\ a_{r1} & \dots & a_{rc} \end{pmatrix}_{r \times c} = [a_{ij}]_{\substack{i=1,2,\dots,r \\ j=1,2,\dots,c}}$$

$$A = \begin{pmatrix} a_{11} & A_{rc} \\ \vdots & \vdots \\ a_{1c} & a_{rc} \end{pmatrix}_{r \times c} = [a_{ij}]_{\substack{j=1,2,\dots,r \\ i=1,2,\dots,c}}$$

3-12 تساوي المصفوفات (Equality of Matrices)

إن مصفوفتين يقال أنهما متساويتان إذا كان لهما الأبعاد نفسها وأن كل
العناصر المتناظرة متساوية ، إذا تساوت مصفوفتان فإن عناصرهما المتناظرة
تكون متساوية .

مثلاً :

$$A = \begin{pmatrix} a_1 \\ a_2 \\ a_3 \end{pmatrix} \quad B = \begin{pmatrix} 4 \\ 7 \\ 3 \end{pmatrix}$$

عندئذ فإن تساوي (A) مع (B) أي (A=B) يتضمن أن :

$$a_1 = 4$$

$$a_2 = 7$$

$$a_3 = 3$$

وبالطريقة نفسها اذا كان لدينا المصفوفتين :

$$A = \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \\ a_{31} & a_{32} \end{pmatrix} \quad B = \begin{pmatrix} 17 & 2 \\ 14 & 5 \\ 13 & 9 \end{pmatrix}$$

عندئذ فإن (A=B) يتضمن :

$$a_{11} = 17$$

$$a_{12} = 2$$

$$a_{21} = 14$$

$$a_{22} = 5$$

$$a_{31} = 13$$

$$a_{32} = 9$$

4-12 أمثلة إنحدار (Regression Examples)

في تحليل الانحدار فإن واحدة من المصفوفات الأساسية هي متجه (Y)

تتألف من (n) من المشاهدات حول المتغير المعتمد (Y) .

$$Y = \begin{pmatrix} Y_1 \\ Y_2 \\ \cdot \\ \cdot \\ Y_n \end{pmatrix}$$

$n \times 1$

يجب أن نلاحظ أن (Y^1) (مقلوبة) هو متجه صف الآتي :

$$Y^1_{1 \times n} = \begin{bmatrix} Y_1 & Y_2 & \dots & Y_n \end{bmatrix}$$

وهناك مصفوفة أساسية أخرى في تحليل الانحدار هي مصفوفة (X)

والتي تعرف في تحليل الانحدار كما يأتي :

$$X = \begin{pmatrix} 1 & X_1 \\ 1 & X_2 \\ \cdot & \cdot \\ \cdot & \cdot \\ 1 & X_n \end{pmatrix}$$

$n \times 2$

إن مصفوفة (X) تتألف من عمود الـ (1) وعمود ثاني يحتوي على قيم

المتغير التوضيحي (X_i) ، لاحظ أن مقلوبة مصفوفة (X_i) هي :

$$X^1 = \begin{pmatrix} 1 & 1 & 1 & \dots & 1 \\ X_1 & X_2 & X_3 & \dots & X_n \end{pmatrix}$$

$2 \times n$

مثال من الانحدار :

الجدول الآتي يبين أو يعرض بيانات عن المتغير المعتمد (Y) والمتغير

التوضيحي (X) :

المشاهدة	X_i	Y_i
1	30	73
2	20	50
3	60	128
4	80	170
5	40	87
6	50	108
7	60	135
8	30	69
9	20	56
10	60	132

إن عرض هذه البيانات بصيغة المصفوفات كما يأتي :

$$Y = \begin{pmatrix} 73 \\ 50 \\ . \\ . \\ . \\ . \\ 132 \end{pmatrix} \quad X = \begin{pmatrix} 1 & 30 \\ 1 & 20 \\ . & . \\ . & . \\ . & . \\ . & . \\ 1 & 60 \end{pmatrix}$$

5-12 جمع وطرح المصفوفات (Matrix Addition and Subtraction)

إن إضافة أو طرح مصفوفتين يتطلب ان تكونا ذا أبعاد متساوية ، إن مجموع أو فرق مصفوفتين هو مصفوفة أخرى عناصرها تتكون من مجموع أو فرق العناصر المتناظرة للمصفوفتين .

إفترض أن :

$$A = \begin{pmatrix} 1 & 4 \\ 2 & 5 \\ 3 & 6 \end{pmatrix}_{3 \times 2} \quad B = \begin{pmatrix} 1 & 2 \\ 2 & 3 \\ 3 & 4 \end{pmatrix}$$

بعد ذلك :

$$A + B = \begin{pmatrix} 1+1 & 4+2 \\ 2+2 & 5+3 \\ 3+3 & 6+4 \end{pmatrix}_{3 \times 2} = \begin{pmatrix} 2 & 6 \\ 4 & 8 \\ 6 & 10 \end{pmatrix}$$

وبالطريقة نفسها فإن :

$$A - B = \begin{pmatrix} 1-1 & 4-2 \\ 2-2 & 5-3 \\ 3-3 & 6-4 \end{pmatrix} = \begin{pmatrix} 0 & 2 \\ 0 & 2 \\ 0 & 2 \end{pmatrix}$$

وعلى نحو عام :

$$A = \begin{pmatrix} a_{ij} \end{pmatrix}_{r \times c} \quad B = \begin{pmatrix} b_{ij} \end{pmatrix}_{r \times c} \quad \begin{matrix} I=1,2,\dots,r \\ J=1,2,\dots,c \end{matrix}$$

بعد ذلك فإن :

$$A+B = \begin{pmatrix} a_{ij} + b_{ij} \end{pmatrix}_{r \times c} \quad A-B = \begin{pmatrix} a_{ij} - b_{ij} \end{pmatrix}_{r \times c}$$

مثال من الانحدار :

$$Y_i = E(Y_i) + e_i \quad i=1,2,\dots,n \quad \text{إن نموذج الانحدار الآتي :}$$

يمكن ان يكتب :

$$\begin{pmatrix} Y_1 \\ Y_2 \\ \cdot \\ \cdot \\ Y_n \end{pmatrix} = \begin{pmatrix} E(Y_1) \\ E(Y_2) \\ \cdot \\ \cdot \\ E(Y_n) \end{pmatrix} + \begin{pmatrix} e_1 \\ e_2 \\ \cdot \\ \cdot \\ e_n \end{pmatrix}$$

وهكذا فإن مصفوفة (Y) تساوي مجموع مصفوفتين :

مصفوفة تحتوي على القيم المتوقعة للمتغير المعتمد (Y) .

ومصفوفة أخرى تحتوي على قيم الخطأ (Error Terms) أو قيم المتغير

العشوائي (ei) .

2-12 ضرب المصفوفات (Matrix Multiplication)

أولاً : ضرب المصفوفة برقم إعتيادي (A Scalar) أو رمز يمثل رقماً

إن الـ (Scalar) هو ليس مصفوفة ، غالباً ما نواجه ضرب مصفوفة برقم إعتيادي ، وفي هذا المجال فإن كل عنصر في المصفوفة يضرب بالرقم الإعتيادي الـ (Scalar) ، مثلاً إفترض المصفوفة (A) معطاه كما يأتي :

$$A = \begin{pmatrix} 2 & 7 \\ 9 & 3 \end{pmatrix}$$

وبعد ذلك فإن (4A) عندما يكون (4) هو رقم إعتيادي والنتيجة كما

يأتي :

$$4A = \begin{pmatrix} 2 & 7 \\ 9 & 3 \end{pmatrix} = \begin{pmatrix} 8 & 28 \\ 36 & 12 \end{pmatrix}$$

وبالطريقة نفسها فإن (TA) تساوي :

$$TA = \begin{pmatrix} 2 & 7 \\ 9 & 3 \end{pmatrix} = \begin{pmatrix} 2T & 7T \\ 9T & 3T \end{pmatrix}$$

عندما تكون (T) رقم إعتيادي أو رمز .

إذا كان هناك عنصراً مشتركاً بين عناصر المصفوفة فإن ذلك العنصر

المشترك يمكن أن يكون خارج المصفوفة ويعامل بوصفه رقماً إعتيادياً . (A Scalar)

مثلاً :

$$\begin{pmatrix} 9 & 27 \\ 15 & 18 \end{pmatrix} = 3 \begin{pmatrix} 3 & 9 \\ 5 & 6 \end{pmatrix}$$

وبالطريقة نفسها فإن :

$$\begin{bmatrix} \frac{2}{T} & \frac{2}{T} \\ \frac{3}{T} & \frac{8}{T} \end{bmatrix} = \frac{1}{T} \begin{bmatrix} 5 & 2 \\ 3 & 8 \end{bmatrix}$$

وعموماً فإنه إذا كان :

$$A = [a_{ij}]$$

وإن (T) رقماً إعتيادياً فإننا نحصل على :

$$T \square A = T A = \begin{bmatrix} T a_{ij} \end{bmatrix}$$

ثانياً : ضرب مصفوفة بمصفوفة أخرى .

إن ضرب مصفوفة بمصفوفة أخرى ربما يبدو معقداً بعض الشيء في

البداية ولكن الممارسة ستجعل المسألة روتينية ، لنأخذ المصفوفتين الاتيتين :

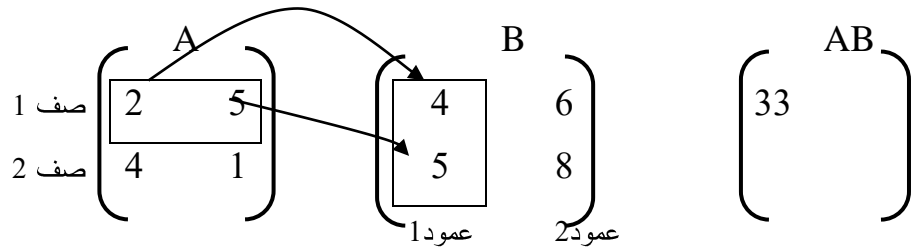
$$A = \begin{matrix} & & \begin{pmatrix} 2 & 5 \\ 4 & 1 \end{pmatrix} \\ 2 \times 2 \end{matrix} \quad B = \begin{matrix} & & \begin{pmatrix} 4 & 6 \\ 5 & 8 \end{pmatrix} \\ 2 \times 2 \end{matrix}$$

إن حاصل الضرب ينتج (AB) الذي سيكون عبارة عن مصفوفة

أبعادها (2×2) وعناصرها تحسب من خلال إيجاد ناتج ضرب صفوف (rows)

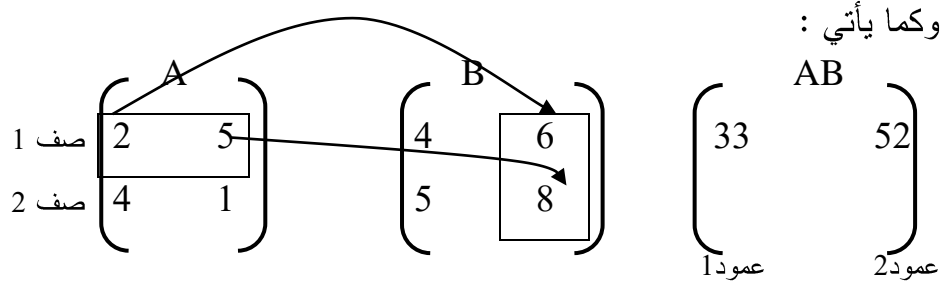
المصفوفة (A) في أعمدة المصفوفة (B) وجمع تلك النواتج .

مثلاً لإيجاد عناصر الصف الأول والعمود الأول لحاصل ضرب (AB) فإننا نعمل الصف الأول من (A) والعمود الأول من (B) كما يأتي :



$$(2) \times (4) + (5) \times (5) = 33$$

إن الرقم (33) هو عنصر في الصف الأول والعمود الأول من المصفوفة (AB) ولإيجاد عنصر في الصف الأول والعمود الثاني للمصفوفة (AB) ، فإننا نعمل مع الصف الأول لـ (A) والعمود الثاني لـ (B) .



وحاصل الضرب يكون كما يأتي :

$$(2)(6) + (5)(8) = 52$$

والعناصر الأخرى تحسب بالطريقة نفسها :

$$(4)(4) + (1)(5) = 21$$

$$AB = \begin{pmatrix} 33 & 52 \\ 21 & \end{pmatrix}$$

$$(4)(6) + (1)(8) = 32$$

$$AB = \begin{pmatrix} 33 & 52 \\ 21 & 32 \end{pmatrix}$$

لنأخذ مثالاً آخر :

$$A = \begin{pmatrix} 1 & 3 & 4 \\ 0 & 5 & 8 \end{pmatrix}$$

$$B = \begin{pmatrix} 3 \\ 5 \\ 2 \end{pmatrix}$$

$$AB = \begin{pmatrix} 1 & 3 & 4 \\ 0 & 5 & 8 \end{pmatrix} \begin{pmatrix} 3 \\ 5 \\ 2 \end{pmatrix} = \begin{pmatrix} 26 \\ 41 \end{pmatrix}$$

$$(1)(3) + (3)(5) + (4)(2) = 26$$

$$(0)(3) + (5)(5) + (8)(2) = 41$$

أمثلة أخرى :

مثال أول :

$$\begin{pmatrix} 4 & 2 \\ 5 & 8 \end{pmatrix} \begin{pmatrix} a_1 \\ a_2 \end{pmatrix} = \begin{pmatrix} 4a_1 & 2a_2 \\ 5a_1 & 8a_2 \end{pmatrix}$$

مثال ثاني :

$$\begin{bmatrix} 2 & 3 & 5 \end{bmatrix} \begin{bmatrix} 2 \\ 5 \\ 3 \end{bmatrix} = \begin{bmatrix} 22+ & 32+ & 52 \end{bmatrix} = \begin{bmatrix} 38 \end{bmatrix}$$

مثال ثالث :

$$\begin{pmatrix} 1 & X_1 \\ 1 & X_2 \\ 1 & X_3 \end{pmatrix} \begin{pmatrix} b_0 \\ b_1 \end{pmatrix} = \begin{pmatrix} b_0 + b_1 X_1 \\ b_0 + b_1 X_2 \\ b_0 + b_1 X_3 \end{pmatrix}$$

7-12 أمثلة في استخدام المصفوفات في تحليل الانحدار

لنعرف متجه (Vector) المعلمات (b) كما يأتي :

$$b = \begin{pmatrix} b_0 \\ b_1 \end{pmatrix}$$

عندئذ فإن منتج (Xb) عندما يكون (X) متغير معرف بالصيغة الآتية

في مصفوفة (n × 1) :

$$X = \begin{pmatrix} 1 & X_1 \\ 1 & X_2 \\ \vdots & \vdots \\ 1 & X_n \end{pmatrix}$$

$$Xb = \begin{pmatrix} 1 & X_1 \\ 1 & X_2 \\ \vdots & \vdots \\ 1 & X_n \end{pmatrix} \begin{pmatrix} b_0 \\ b_1 \end{pmatrix} = \begin{pmatrix} b_0 + b_1 X_1 \\ b_0 + b_1 X_2 \\ \vdots \\ b_0 + b_1 X_n \end{pmatrix}$$

وطالما ان $E(y_i) = b_0 + b_1 X_i$ فإننا نرى أن (Xb) هو متجه القيمة المتوقعة $(E(y_i))$ لنموذج الانحدار الخطي البسيط .
هناك حاصل ضرب آخر نكون بحاجة إليه وهو $(Y^1 Y)$ عندما يكون (Y) هو قيمة مشاهدات المتغير المعتمد معرف كما يلي :

$$Y = \begin{matrix} Y_1 \\ Y_2 \\ . \\ . \\ Y_n \end{matrix} \quad n \times 1$$

$$Y^1 Y = \begin{bmatrix} Y_1 & Y_2 & \dots & Y_n \end{bmatrix} \begin{bmatrix} Y_1 \\ Y_2 \\ . \\ . \\ Y_n \end{bmatrix} = \begin{bmatrix} Y_1^2 + Y_2^2 + \dots + Y_n^2 \end{bmatrix} = \left[\sum Y_i^2 \right]$$

يجب ان نلاحظ أن $(Y^1 Y)$ هي مصفوفة بأبعاد (1×1) .

وهكذا فإننا حصلنا على طريقة لكتابة مجموع تربيع (Y)

$$Y^1 Y = \sum Y_i^2$$

كما أننا سوف نحتاج الى $(X^1 X)$ هذه مصفوفة بأبعاد (2×2) .

$$X^1 X = \begin{matrix} 2 \times 2 \end{matrix} \begin{bmatrix} 1 & 1 & \dots & 1 \\ X_1 & X_2 & \dots & X_n \end{bmatrix} \begin{bmatrix} 1 & X_1 \\ 1 & X_2 \\ . & . \\ . & . \\ 1 & X_n \end{bmatrix} = \begin{bmatrix} n & \sum X_i \\ \sum X_i & \sum X_i^2 \end{bmatrix}$$

وكذلك سوف نحتاج الى (X^1Y) وهو مصفوفة بأبعاد 1×2 :

$$X^1Y = \begin{pmatrix} 1 & 1 & \dots & 1 \\ X_1 & X_2 & \dots & X_n \end{pmatrix} \begin{pmatrix} Y_1 \\ Y_2 \\ \cdot \\ \cdot \\ Y_n \end{pmatrix} = \begin{bmatrix} \sum Y_i \\ \sum X_i Y_i \end{bmatrix}$$

8-12 أنواع خاصة من المصفوفات

1-8-12 المصفوفة المتشابهة (Symmetric Matrix)

إذا كانت $(A^1=A)$ فإن (A) يقال عنها أنها متشابهة وهكذا فإن (A)

الآتية متشابهة :

$$A = \begin{pmatrix} 1 & 4 & 6 \\ 4 & 2 & 5 \\ 6 & 5 & 3 \end{pmatrix} \quad A^1 = \begin{pmatrix} 1 & 4 & 6 \\ 4 & 2 & 5 \\ 6 & 5 & 3 \end{pmatrix}$$

إن المصفوفة المتشابهة بالضرورة مصفوفة مربعة والمصفوفات

المتشابهة تظهر بصيغة نموذج في تحليل الانحدار قبل أن نضرب المصفوفة

(X) في مقلوبتها (X^1) (Transpose) .

والمصفوفة الناتجة (X^1X) .

2-8-12 مصفوفة القطرية ((الدايagonal Matrix))

إن مصفوفة القطر الدايagonal (X) هي مصفوفة مربعة تكون عناصرها غير الموجودة على الدايagonal جميعها صفراً ، مثلاً :

$$A = \begin{pmatrix} a_{11} & 0 & 0 \\ 0 & a_{22} & 0 \\ 0 & 0 & a_{33} \end{pmatrix} \quad B = \begin{pmatrix} 4 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 10 & 0 \\ 0 & 0 & 0 & 5 \end{pmatrix}$$

3-8-12 معكوس المصفوفة (Inverse of Matrix)

في علم الجبر الإعتيادي فإن المعكوس (Inverse) لرقم معين هو الرقم المتبادل معه (Reciprocal) . وهكذا فإن معكوس الرقم (6) هو $(\frac{1}{6})$.

إن الرقم المضروب في معكوسه يساوي دائماً (1) :

$$6 \cdot \frac{1}{6} = 1$$

$$X \cdot \frac{1}{X} = X \cdot X^{-1} = 1$$

وفي جبر المصفوفات فإن معكوس المصفوفة (A) هي مصفوفة أخرى

يشار إليها بـ (A^{-1}) مثل :

$$A^{-1}A = AA^{-1} = I$$

عندما يكون (I) هو متطابقة المصفوفة . وهكذا فإن متطابقة المصفوفة

(I) تلعب الدور نفسه الذي يلعبه الرقم (1) في الجبر الإعتيادي .

إن معكوس المصفوفة (Inverse) يعرف فقط للمصفوفات المربعة .

وحتى بالنسبة للمصفوفات المربعة فإن عدة مصفوفات مربعة ليس لها معكوس :

أمثلة : 1- معكوس المصفوفة :

$$A = \begin{bmatrix} 2 & 4 \\ 3 & 1 \end{bmatrix}$$

هو :

$$A^{-1} = \begin{pmatrix} -.1 & 4. \\ .3 & -.2 \end{pmatrix}$$

طالما أن :

$$A^{-1}A = \begin{pmatrix} -.1 & 4. \\ .3 & -.2 \end{pmatrix} \begin{bmatrix} 2 & 4 \\ 3 & 1 \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$$

أو :

$$AA^{-1} = \begin{bmatrix} 2 & 4 \\ 3 & 1 \end{bmatrix} \begin{pmatrix} -.1 & .4 \\ .3 & -.2 \end{pmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$$

2- معكوس المصفوفة

$$A = \begin{pmatrix} 3 & 0 & 0 \\ 0 & 4 & 0 \\ 0 & 0 & 2 \end{pmatrix}$$

هو :

$$A^{-1} = \begin{pmatrix} \frac{1}{3} & 0 & 0 \\ 0 & \frac{1}{4} & 0 \\ 0 & 0 & \frac{1}{2} \end{pmatrix}$$

طالما أن :

$$A^{-1}A = \begin{pmatrix} \frac{1}{3} & 0 & 0 \\ 0 & \frac{1}{4} & 0 \\ 0 & 0 & \frac{1}{2} \end{pmatrix} \begin{pmatrix} 3 & 0 & 0 \\ 0 & 4 & 0 \\ 0 & 0 & 2 \end{pmatrix} \\ = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix}$$

4-8-12 إيجاد معكوس المصفوفة

إن إيجاد معكوس المصفوفة (The Inverse) يمكن غالباً ما يتطلب عمليات حسابية كثيرة . وهنا سنكتفي بمعكوس المصفوفة (2×2) والمصفوفة (3×3) أي كيفية حسابها . أما المصفوفات الأكبر فيعتمد في حساب معكوس المصفوفة لها على حاسبات إلكترونية ضخمة .

يمكن أن نبين أن معكوس المصفوفة (2×2) أو (3×3) يحسب كما يأتي

إذا كانت :

$$A = \begin{pmatrix} a & b \\ c & d \end{pmatrix}$$

عندئذ فإن :

$$A^{-1} = \begin{bmatrix} a & b \\ c & d \end{bmatrix}^{-1} = \begin{bmatrix} \frac{d}{D} & \frac{-b}{D} \\ \frac{-c}{D} & \frac{a}{D} \end{bmatrix}$$

عندما يكون :

$$ad-bc=D$$

D هو محدد (Deteminant) المصفوفة (A)

مثال : أوجد معكوس المصفوفة الآتية :

$$A = \begin{bmatrix} 2 & 4 \\ 3 & 1 \end{bmatrix}$$

لدينا : $a=2$

$b=4$

$c=3$

$d=1$

$$D=ad-bc$$

$$=(2)(1)-(4)(3)=-10$$

ولذلك :

$$A^{-1} = \begin{bmatrix} \frac{1}{-10} & \frac{-4}{-10} \\ \frac{-3}{-10} & \frac{2}{-10} \end{bmatrix} = \begin{bmatrix} -.1 & .4 \\ .3 & -.2 \end{bmatrix}$$

مثال على الإنحدار :

إن معكوس المصفوفة في تحليل الإنحدار هو معكوس (Inverse)

المصفوفة (X^1X) السابقة :

$$X'X = \begin{bmatrix} 1 & 1 & \dots & 1 \\ X_1 & X_2 & \dots & X_n \end{bmatrix} \begin{bmatrix} 1 & X_1 \\ 1 & X_2 \\ \vdots & \vdots \\ 1 & X_n \end{bmatrix} = \begin{bmatrix} n & \sum X_i \\ \sum X_i & \sum X_i^2 \end{bmatrix}$$

وباستخدام قاعدة حساب المعكوس (Inverse) :

$$\begin{aligned} a &= n & b &= \sum X_i \\ c &= \sum X_i & d &= \sum X_i^2 \end{aligned}$$

إذاً :

$$\begin{aligned} D &= n\sum X_i^2 - (\sum X_i)(\sum X_i) \\ &= n\sum X_i^2 - (\sum X_i)^2 \\ &= n \left(\sum X_i^2 - \frac{(\sum X_i)^2}{n} \right) \\ &= n\sum (X_i - \bar{X})^2 \end{aligned}$$

12-8-5 إيجاد معكوس المصفوفة بثلاث صفوف وثلاث أعمدة .

إذا كان لدينا المصفوفة الآتية :

$$X = \begin{bmatrix} a & b & c \\ d & e & f \\ g & h & k \end{bmatrix}$$

فإن معكوس هذه المصفوفة :

$$X^{-1} = \begin{bmatrix} a & b & c \\ d & e & f \\ g & h & k \end{bmatrix}^{-1} = \begin{bmatrix} A & B & C \\ D & E & F \\ G & H & K \end{bmatrix}$$

عندما يكون :

$$\begin{aligned} A &= \frac{(ek - fh)}{Z} & D &= \frac{-(dk - fg)}{Z} & G &= \frac{(dh - eg)}{Z} \\ B &= \frac{(bk - ch)}{Z} & E &= \frac{(ak - cg)}{Z} & H &= \frac{-(ah - bg)}{Z} \\ C &= \frac{(bf - ce)}{Z} & F &= \frac{-(af - cd)}{Z} & K &= \frac{(ae - bd)}{Z} \\ Z &= a(ek - fh) - b(dk - fg) + c(dh - eg) \end{aligned}$$

9-12 مثال على تحليل الانحدار المتعدد بمتغيرين توضيحيين باستخدام المصفوفات .

النموذج الآتي يتضمن جدول البيانات حول المبيعات حسب المناطق (Y_i) وهو المتغير المعتمد ، وبيانات حول المتغير التوضيحي عدد السكان في المنطقة (X_1) والمتغير التوضيحي الثاني الفردي (per capita) في المنطقة (X_2) . وفي هذه الحالة فإن النموذج من الدرجة الأولى هو :

$$Y_i = b_0 + b_1X_{i1} + b_2X_{i2} + \varepsilon_i$$

جدول البيانات

المنطقة	المبيعات بالعدد Y_i	السكان بآلاف الأفراد X_{i1}	الدخل الفردي X_{i2}
1	162	274	2450
2	120	180	3254
3	223	375	3802
4	131	205	2838
5	67	86	2347
6	169	265	3782
7	81	98	3008
8	192	330	2450
9	116	195	2137
10	55	53	2560
11	252	430	4020
12	232	372	4427
13	144	236	2660
14	103	157	2088
15	212	370	2605

حسابات أساسية :

$$1. X^1X = \begin{bmatrix} 1 & 1 & . & . & . & 1 \\ 274 & 180 & . & . & . & 370 \\ 2450 & 2254 & . & . & . & 2605 \end{bmatrix} \begin{bmatrix} 1 & 274 & 2450 \\ 1 & 180 & 3254 \\ . & . & . \\ . & . & . \\ . & . & . \\ 1 & 370 & 2605 \end{bmatrix} \text{ أولاً :}$$

والذي ينتج عن هذه العملية هو :

$$X^1X = \begin{bmatrix} 15 & 3626 & 44428 \\ 3626 & 1067614 & 11419181 \\ 44428 & 11419181 & 139063428 \end{bmatrix}$$

$$2. X^1Y = \begin{bmatrix} 1 & 1 & . & . & . & 1 \\ 274 & 180 & . & . & . & 370 \\ 2450 & 3254 & . & . & . & 2605 \end{bmatrix} \begin{bmatrix} 162 \\ 120 \\ . \\ . \\ . \\ 212 \end{bmatrix} \text{ ثانياً :}$$

والذي ينتج عن هذه العملية هو :

$$X^1Y = \begin{bmatrix} 2259 \\ 647107 \\ 7096619 \end{bmatrix}$$

$$3. X^1 X^{-1} = \begin{bmatrix} 15 & 3626 & 44428 \\ 3626 & 1067614 & 11419181 \\ 44428 & 11419181 & 139063428 \end{bmatrix} \quad \text{ثالثاً :}$$

عندما يكون :

$$\begin{aligned} a &= 15 & b &= 3626 & c &= 44428 & d &= 3626 \\ e &= 1067614 & f &= 11419181 & g &= 44428 & h &= 11419181 \\ k &= 139063428 \end{aligned}$$

$$Z = 1449704406 \ 0000$$

$$A = 1246348416 \quad \text{إذاً فإن محدد هذه المصفوفة هو } (Z) :$$

$$B = 0.0002129664 \ 176$$

وهكذا .

وجبرياً نلاحظ أن $X^1 X$ لنموذج الدرجة الأولى مع متغيرين توضيحيين :

$$X^1 X = \begin{bmatrix} 1 & 1 & . & . & . & 1 \\ X_{11} & X_{21} & . & . & . & X_{n1} \\ X_{12} & X_{22} & . & . & . & X_{n2} \end{bmatrix} \begin{bmatrix} 1 & X_{11} & X_{12} \\ 1 & X_{21} & X_{22} \\ . & . & . \\ . & . & . \\ . & . & . \\ 1 & X_{n1} & X_{n2} \end{bmatrix}$$

$$X^1 X = \begin{bmatrix} n & \sum X_{i1} & \sum X_{i2} \\ \sum X_{i1} & \sum X_{i1}^2 & \sum X_{i1} X_{i2} \\ \sum X_{i2} & \sum X_{i2} X_{i1} & \sum X_{i2}^2 \end{bmatrix}$$

وهكذا في مثالنا نجد أن :

$$n = 15$$

$$\sum X_{i1} = 274 + 180 + \dots = 3626$$

$$\sum X_{i1} X_{i2} = (274)(2450) + (180)(3254) + \dots = 11419181$$

والى آخره .

وأيضاً يجب أن نلاحظ أن قيمة (X^1Y) للنموذج السابق يمكن أن تحسب كما يأتي :

$$X^1Y = \begin{bmatrix} 1 & 1 & . & . & . & 1 \\ X_{i1} & X_{21} & . & . & . & X_{n1} \\ X_{i2} & X_{22} & . & . & . & X_{n2} \end{bmatrix} \begin{bmatrix} Y_1 \\ Y_1 \\ . \\ . \\ . \\ Y_n \end{bmatrix} = \begin{bmatrix} \sum Y_i \\ \sum X_{i1} Y_i \\ \sum X_{i2} Y_i \end{bmatrix}$$

مثلاً يكون لدينا :

$$\sum Y_i = 162 + 120 + = 2259$$

$$\sum X_{i1} Y_i = (274)(162) + (180)(120) + = 647107$$

$$\sum X_{i2} Y_i = (2450)(162) + (3254)(120) + = 7096619$$

ولتقدير معاملات العلاقة نستخدم ما يأتي :

$$b = (X^1X)^{-1} X^1Y$$

$$\begin{bmatrix} b_0 \\ b_1 \\ b_2 \end{bmatrix} = \begin{bmatrix} 3.45 \\ 0.496 \\ 0.00920 \end{bmatrix}$$

ولذلك فإن :

$$(X^1X)^{-1} = \begin{bmatrix} \frac{\sum X_i^2}{n \sum (X_i - \bar{X})^2} & \frac{-\sum X_i}{n \sum (X_i - \bar{X})^2} \\ \frac{-\sum X_i}{n \sum (X_i - \bar{X})^2} & \frac{n}{n \sum (X_i - \bar{X})^2} \end{bmatrix}$$

ولأن : $\sum X_i = n\bar{X}$

نستطيع أن نبسط أكثر :

$$(X^T X)^{-1} = \begin{bmatrix} \frac{\sum X_i^2}{n \sum (X_i - \bar{X})^2} & \frac{-\bar{X}}{n \sum (X_i - \bar{X})^2} \\ \frac{-\bar{X}}{n \sum (X_i - \bar{X})^2} & \frac{1}{n \sum (X_i - \bar{X})^2} \end{bmatrix}$$

12-9-1 استخدام معكوس المصفوفة .

إفترض أن لدينا المعادلتين الآتيتين :

$$2x + 4y = 20$$

$$3x + y = 10$$

يمكن كتابة المعادلتين بصيغة المصفوفة كما يأتي :

$$\begin{bmatrix} 2 & 4 \\ 3 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} = \begin{bmatrix} 20 \\ 10 \end{bmatrix}$$

إن حل هاتين المعادلتين هو :

$$\begin{bmatrix} x \\ y \end{bmatrix} = \begin{bmatrix} 2 & 4 \\ 3 & 1 \end{bmatrix}^{-1} \begin{bmatrix} 20 \\ 10 \end{bmatrix}$$

$$D = ad - bc$$

$$= 2 - 12 = -10$$

$$\begin{bmatrix} x \\ y \end{bmatrix} = \begin{bmatrix} \frac{1}{-10} & \frac{-4}{-10} \\ \frac{-3}{-10} & \frac{2}{-10} \end{bmatrix}^{-1} \begin{bmatrix} 20 \\ 10 \end{bmatrix} = \begin{bmatrix} 2 \\ 4 \end{bmatrix}$$

$$\begin{bmatrix} x \\ y \end{bmatrix} = \begin{bmatrix} -0.1 & 0.4 \\ 0.3 & -0.2 \end{bmatrix} \begin{bmatrix} 20 \\ 10 \end{bmatrix} = \begin{bmatrix} 2 \\ 4 \end{bmatrix}$$

ولذلك فإن : $2 = x$ ، $4 = y$

$$\begin{aligned} (-0.1)(20) + (0.4)(10) &= 2 \\ (0.3)(20) + (-0.2)(10) &= 4 \end{aligned}$$

10-12 بعض النظريات المهمة للمصفوفات

$A + B = B + A$	النظرية الأولى
$(A + B) + C = A + (B + C)$	النظرية الثانية
$(AB)C = A(BC)$	النظرية الثالثة
$C(A + B) = CA + CB$	النظرية الرابعة
$T(A + B) = TA + TB$	النظرية الخامسة
$(A^1)^1 = A$	النظرية السادسة
$(A + B)^1 = A^1 + B^1$	النظرية السابعة
$(AB)^1 = B^1 A^1$	النظرية الثامنة
$(AB)^{-1} = B^{-1} A^{-1}$	النظرية التاسعة
$(ABC)^{-1} = C^{-1} B^{-1} A^{-1}$	النظرية العاشرة
$(A^{-})^{-1} = A$	النظرية الحادية عشر
$(A1)^{-1} = (A-1)^1$	النظرية الثانية عشر

11-12 المتجه والمصفوفات العشوائية

(Random Vectors and Matrices)

إن المتجه العشوائي أو المصفوفة العشوائية تحتوي على عناصر تمثل متغيرات عشوائية . وهكذا فإن المتجه (Y) هو متجه عشوائي طالما أن (Y_i) هي عناصر متغيرات عشوائية .

توقع المتجه العشوائي أو المصفوفة العشوائية .

لنفترض أن لدينا $3=n$ مشاهدات وأنها نهتم بمتجه المشاهدات :

$$Y = \begin{bmatrix} Y_1 \\ Y_2 \\ Y_3 \end{bmatrix}$$

وهنا نشير الى $E(Y)$ بوصفه متجه :

$$E(Y) = \begin{bmatrix} E(Y_1) \\ E(Y_2) \\ E(Y_3) \end{bmatrix}$$

مثال في الانحدار :

لنفترض أن عدد المشاهدات في تطبيقات الانحدار هي $n = 3$ ، وهنا فإن الأخطاء العشوائية الثلاثة (Error Terms) $(\varepsilon_3, \varepsilon_2, \varepsilon_1)$ لكل منها توقع صفر . فإذا عرفنا متجه الخطأ :

$$\varepsilon = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \end{bmatrix}$$

ويكون لدينا : $E(\varepsilon) = 0$

طالما أن :

$$E(\varepsilon) = \begin{bmatrix} E(\varepsilon_1) \\ E(\varepsilon_2) \\ E(\varepsilon_3) \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$$

12-12 مصفوفة التباين والتباين المشترك للمتجه العشوائي .

لنأخذ مره أخرى المتجه العشوائي (Y) المؤلف أو المكون من ثلاثة مشاهدات Y_3, Y_2, Y_1 . ولكل متغيرين عشوائيين لهما تباين مشترك $\delta(Y_i, Y_j)$ (covariance) . نستطيع أن نجمع هذه في مصفوفة تدعى ((مصفوفة التباين والتباين المشترك للمتجه العشوائي (Y))) ويشار له بـ $\delta^2(Y)$

$$\delta^2(Y) = \begin{bmatrix} \delta^2(Y_1) & \delta(Y_1, Y_2) & \delta(Y_1, Y_3) \\ \delta(Y_2, Y_1) & \delta^2(Y_2) & \delta(Y_2, Y_3) \\ \delta(Y_3, Y_1) & \delta(Y_3, Y_2) & \delta^2(Y_3) \end{bmatrix}$$

يجب أن نلاحظ أن التباينات تقع على الداكنال (main diagonal) بينما التباينات المشتركة $\delta(Y_i, Y_j)$ تقع على الصفوف والأعمدة .

12-13 نموذج الانحدار الخطي البسيط بصيغ المصفوفات .

نحن الآن جاهزون لتطوير صيغ مصفوفات للانحدار الخطي البسيط .
يجب أن نتذكر مره أخرى أننا سوف لن نعرض نتائج جديدة ولكن فقط نضع صيغ المصفوفات للنتائج التي تم الحصول عليها في البداية .
يجب أن نبدأ مع نموذج الانحدار الآتي :

$$i = 1, 2, \dots, n \quad Y_i = b_0 + b_1 X_i + \varepsilon_i$$

وهذا يتضمن ما يأتي :

$$Y_1 = b_0 + b_1 X_1 + \varepsilon_1$$

$$Y_2 = b_0 + b_1 X_2 + \varepsilon_2$$

.

.

.

$$Y_n = b_0 + b_1 X_n + \varepsilon_n$$

لقد عرفنا في البداية أو في الجزء السابق متجه المشاهدات (Y) ومصفوفة المتغير التوضيحي (X) ومصفوفة المعلمات (b) ولنعيد هذه التعريفات الآن :

$$Y = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} \quad X = \begin{bmatrix} 1 & X_1 \\ 1 & X_2 \\ \vdots & \vdots \\ 1 & X_n \end{bmatrix} \quad b = \begin{bmatrix} b_0 \\ b_1 \end{bmatrix} \quad \varepsilon = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix}$$

وهنا نستطيع أن نكتب هذه الصيغة بإختصار :

$$\begin{matrix} \varepsilon_n & \mathbf{Y} & = & \mathbf{X} & \mathbf{b} & + \\ nx1 & nx2 & 2x1 & nx1 & \end{matrix}$$

وطالما أن :

$$\begin{bmatrix} Y_1 \\ Y_2 \\ . \\ . \\ . \\ Y_n \end{bmatrix} = \begin{bmatrix} 1 & X_1 \\ 1 & X_2 \\ . & X_3 \\ . & . \\ . & . \\ 1 & X_n \end{bmatrix} \begin{bmatrix} b_0 \\ b_1 \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ . \\ . \\ . \\ \varepsilon_n \end{bmatrix} = \begin{bmatrix} b_0 + b_1 X_1 + \varepsilon_1 \\ b_0 + b_1 X_2 + \varepsilon_2 \\ . \\ . \\ . \\ b_0 + b_1 X_n + \varepsilon_n \end{bmatrix}$$

إن عمود الـ (1) في مصفوفة الـ (X) ربما ينظر اليه بوصفه يتكون من متغير عشوائي $X_0=1$ في نموذج الانحدار

$$1 = X_0 \varepsilon_i \quad Y_i = b_0 X_0 + b_1 X_i +$$

وهكذا فإن مصفوفة (X) ربما تعتبر أنها تحتوي متجه عمود (a Column Vector) لمتغير وهمي (أصم) (a dummy variables) ومتجه عمود آخر يتألف من قيم المتغير التوضيحي (X_i) .

أما بالنسبة للمتغير العشوائي أو حدود الخطأ فإننا نفترض أن :

$$E(\varepsilon_i) = 0 \quad \text{وأن} \quad \delta_{(\varepsilon)}^2 = \delta^2 \quad \text{وأن} \quad \varepsilon_i \text{ هي متغيرات عشوائية}$$

إعتيادية مستقلة . إن الشرط $E(\varepsilon_i) = 0$ بصيغة المصفوفة هو :

$$E \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ . \\ . \\ \varepsilon_n \end{bmatrix} = \begin{bmatrix} E(\varepsilon_1) \\ E(\varepsilon_2) \\ . \\ . \\ E(\varepsilon_n) \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ . \\ . \\ 0 \end{bmatrix}$$

إن الشرط أن المتغير العشوائي له تباين ثابت (δ^2) وإن كل التباينات المشتركة $\delta(\varepsilon_i, \varepsilon_j)$ بالنسبة الى $j \neq i$ هي صفر . ولذلك فإن مصفوفة التباين والتباين المشترك (Variance-Covariance Matrix) :

$$\delta^2(\varepsilon) = \delta^2 I_{n \times n}$$

$$\delta^2(\varepsilon) = \delta^2 \begin{bmatrix} 1 & 0 & 0 & . & . & . & 0 \\ 0 & 1 & 0 & . & . & . & 0 \\ . & . & . & & & & . \\ . & . & . & & & & . \\ . & . & . & & & & . \\ 0 & 0 & 0 & . & . & . & 1 \end{bmatrix} = \begin{bmatrix} \delta^2 & 0 & 0 & 0 & . & . & 0 \\ 0 & \delta^2 & 0 & 0 & . & . & 0 \\ . & . & . & . & & & . \\ . & . & . & . & & & . \\ . & . & . & . & & & . \\ 0 & 0 & 0 & 0 & . & . & \delta^2 \end{bmatrix}$$

وهكذا فإن النموذج بصيغة المصفوفة هو :

$$Y = Xb + \varepsilon$$

عندما يكون ε متجه قيم المتغير العشوائي الذي يتصف بما يأتي :

$$E(\varepsilon) = 0 \quad \delta^2_{(\varepsilon)} = \delta^2 I$$

12-14 تقدير معلمات الانحدار بطريقة المربعات الصغرى .

المعادلات الطبيعية أو الإعتيادية (Normal Equations)

$$nb_0 + b_1 \sum X_i = \sum Y_i$$

$$b_0 \sum X_i + b_1 \sum X_i^2 = \sum X_i Y_i$$

$$X^1 Xb = X^1 Y \quad \text{وبصيغة المصفوفة :}$$

عندما يكون :

$$b = \begin{bmatrix} b_0 \\ b_1 \end{bmatrix}$$

$$\begin{bmatrix} n & \sum X_i \\ \sum X_i & \sum X_i^2 \end{bmatrix} \begin{bmatrix} b_0 \\ b_1 \end{bmatrix} = \begin{bmatrix} \sum Y_i \\ \sum X_i Y_i \end{bmatrix}$$

أو :

$$\begin{bmatrix} nb_0 + b_1 \sum X_i \\ b_0 \sum X_i + b_1 \sum X_i^2 \end{bmatrix} = \begin{bmatrix} \sum Y_i \\ \sum X_i Y_i \end{bmatrix}$$

12-14-1 تقدير معلمات الانحدار .

للحصول على المعلمات المقدرة للانحدار من المعادلات الطبيعية :

$$X^1 X b = X^1 Y$$

وبطرق المصفوفات نضرب الجانبين من مقلوبة المصفوفة لـ $(X^1 X)$:

$$(X^1 X)^{-1} X^1 X b = (X^1 X)^{-1} X^1 Y$$

بحيث نجد :

$$(X^1 X)^{-1} X^1 X = I$$

$$b = (X^1 X)^{-1} X^1 Y$$

مثال : البيانات الآتية عن متغيرين Y و X في الجدول الآتي :

Y _i	X _i	X _i Y _i	X _i ²
73	30	2190	900
50	20	1000	400
128	60	7680	3600
170	80	13600	6400
87	40	3480	1600
108	50	5400	2500
135	60	8100	3600
69	30	2070	900
148	70
132	60
1100	500	61800	28400

$$n = 10 \quad \sum Y_i = 1100 \quad \sum X_i = 500 \quad \sum X_i^2 = 28400 \quad \sum X_i Y_i = 61800$$

$$\begin{aligned} n\Sigma(X_i - \bar{X})^2 &= n\left[\Sigma X_i^2 - \frac{(\Sigma X_i)^2}{n}\right] \\ &= 10\left[28400 - \frac{(500)^2}{10}\right] \\ &= 34000 \end{aligned}$$

ولذلك فإن :

$$\begin{aligned} (X^1 X)^{-1} &= \begin{bmatrix} \frac{\Sigma X_i^2}{n\Sigma(X_i - \bar{X})^2} & \frac{-\Sigma X_i}{n\Sigma(X_i - \bar{X})^2} \\ \frac{-\Sigma X_i}{n\Sigma(X_i - \bar{X})^2} & \frac{n}{n\Sigma(X_i - \bar{X})^2} \end{bmatrix} \\ &= \begin{bmatrix} \frac{28400}{34000} & \frac{-500}{34000} \\ \frac{-500}{34000} & \frac{10}{34000} \end{bmatrix} \\ &= \begin{bmatrix} 0.83529412 & -0.01470588 \\ -0.01470588 & 0.00029412 \end{bmatrix} \end{aligned}$$

وأيضاً :

$$X^1 Y = \begin{bmatrix} \Sigma Y_i \\ \Sigma X_i Y_i \end{bmatrix} = \begin{bmatrix} 1100 \\ 61800 \end{bmatrix}$$

$$b = \begin{bmatrix} b_0 \\ b_1 \end{bmatrix} = (X^1 X)^{-1} X^1 Y = \begin{bmatrix} 0.83529412 & -0.0147 \\ -0.0147 & 0.00029412 \end{bmatrix} \begin{bmatrix} 1100 \\ 61800 \end{bmatrix} = \begin{bmatrix} 10.0 \\ 2.0 \end{bmatrix}$$

15-12 تحليل التباين (Analysis of Variance)

لنجعل متجه (Vector) قيم (Y) المقدرة (\hat{Y}_i) يشار اليه بـ (\hat{Y}) :

$$\hat{Y} = \begin{bmatrix} \hat{Y}_1 \\ \hat{Y}_2 \\ \cdot \\ \cdot \\ \cdot \\ \hat{Y}_n \end{bmatrix}$$

وقيمة (Vector) البواقي $e_i = \hat{Y}_i - Y_i$ يشار اليه بـ (e) :

$$e = \begin{bmatrix} e_1 \\ e_2 \\ \cdot \\ \cdot \\ \cdot \\ e_n \end{bmatrix}$$

وبصيغة إشارات المصفوفات فإن :

$$\begin{aligned} \hat{Y} &= Xb \\ \begin{bmatrix} \hat{Y}_1 \\ \hat{Y}_2 \\ \cdot \\ \cdot \\ \cdot \\ \hat{Y}_n \end{bmatrix} &= \begin{bmatrix} 1 & X_1 \\ 1 & X_2 \\ \cdot & \cdot \\ \cdot & \cdot \\ \cdot & \cdot \\ 1 & X_n \end{bmatrix} \begin{bmatrix} b_0 \\ b_1 \end{bmatrix} = \begin{bmatrix} b_0 + b_1 X_1 \\ b_0 + b_1 X_2 \\ \cdot \\ \cdot \\ \cdot \\ b_0 + b_1 X_n \end{bmatrix} \\ e &= Y - \hat{Y} \end{aligned}$$

إن مجموع المربعات (The Sun of Squares) لتحليل التباين

بإشارات المصفوفات كما يأتي :

$$SSTO = Y^1 Y - n \bar{Y}^2$$

$$SSR = b^1 X^1 Y - n \bar{Y}^2$$

$$SSE = e^1 e = Y^1 Y - b^1 X^1 Y$$

مثال : لإيجاد قيمة (SSE) للمثال السابق بطرق المصفوفات نحن

نعرف سابقاً أن :

$$Y^1 Y = \sum Y_i^2 = 134660$$

ونحن نعرف مسبقاً أن :

$$b = \begin{bmatrix} 10.0 \\ 2.0 \end{bmatrix}$$

$$X^1Y = \begin{bmatrix} 1100 \\ 61800 \end{bmatrix}$$

$$b^1X^1Y = [10.0 \quad 2.0] \begin{bmatrix} 1100 \\ 61800 \end{bmatrix} = 134600$$

$$\begin{aligned} SSE &= Y^1Y - b^1X^1Y \\ &= 134660 - 134600 \\ &= 60 \end{aligned} \quad \text{ولذلك فإن :}$$

مثال ثاني : لنأخذ البيانات الموجودة في الجدول الآتي الذي يتضمن الدخل والإنفاق الإستهلاكي لدولة ما .

الإنفاق الإستهلاكي (Y) بملايين الدنانير	الدخل (X) بملايين الدنانير
70	80
65	100
90	120
95	140
110	160
115	180
120	200
140	220
155	240
150	260

الحل : في حالة وجود متغيرين :

$$\hat{b} = \begin{bmatrix} b_0 \\ b_1 \end{bmatrix}$$

$$X^1X = \begin{bmatrix} 1 & 1 & 1 & . & . & 1 \\ X_1 & X_2 & X_3 & . & . & X_n \end{bmatrix} \begin{bmatrix} 1 & X_1 \\ 1 & X_2 \\ 1 & X_3 \\ . & . \\ . & . \\ 1 & X_n \end{bmatrix} \begin{bmatrix} n & \sum X_i \\ \sum X_i & \sum X_i^2 \end{bmatrix}$$

ثم أن :

$$X^1Y = \begin{bmatrix} 1 & 1 & 1 & . & . & 1 \\ X_1 & X_2 & X_3 & . & . & X_n \end{bmatrix} \begin{bmatrix} Y_1 \\ Y_2 \\ Y_3 \\ . \\ . \\ Y_n \end{bmatrix} \begin{bmatrix} \sum Y_i \\ \sum X_i Y_i \end{bmatrix}$$

وباستخدام البيانات في المثال نحصل على :

$$X^1X = \begin{bmatrix} 10 & 1700 \\ 1700 & 32000 \end{bmatrix}$$

$$X^1Y = \begin{bmatrix} 1110 \\ 205500 \end{bmatrix}$$

وباستعمال قواعد معكوس المصفوفة فإن معكوس المصفوفة (X^1X) هو :

$$(X^1X)^{-1} = \begin{bmatrix} 0.97576 & -0.005152 \\ -0.005152 & 0.0000303 \end{bmatrix}$$

ولذلك فإن :

$$\hat{b} = \begin{bmatrix} \hat{b}_0 \\ \hat{b}_1 \end{bmatrix} = \begin{bmatrix} 0.97576 & -0.005152 \\ -0.005152 & 0.0000303 \end{bmatrix} \begin{bmatrix} 1110 \\ 205500 \end{bmatrix}$$

$$\begin{bmatrix} \hat{b}_0 \\ \hat{b}_1 \end{bmatrix} = \begin{bmatrix} 243571 \\ 0.5079 \end{bmatrix}$$

12-15-1 تقدير قيمة R^2 (معامل التحديد) .

من خلال استخدام القانون الآتي :

$$R^2 = \frac{\hat{b}^1 X^1 Y - N \bar{Y}^2}{Y^1 Y - N \bar{Y}^2}$$

$$\begin{aligned} \hat{b}^1 X^1 Y &= \begin{bmatrix} 243571 & 0.5079 \end{bmatrix} \begin{bmatrix} 1110 \\ 205500 \end{bmatrix} \\ &= 131409.831 \end{aligned}$$

$$Y^1 Y = 132100$$

$$N \bar{Y}^2 = 123210$$

نضع هذه القيم في القانون السابق لـ (R^2) فنحصل على ما يأتي :

$$R^2 = \frac{\hat{b}^1 X^1 Y - N \bar{Y}^2}{Y^1 Y - N \bar{Y}^2}$$

$$= \frac{131409.831 - 123210}{132100 - 123210}$$

$$= 0.9224$$

الفصل الثالث عشر
نماذج المعادلات الآنية

نماذج المعادلات الآتية Simultaneous Equations Models

1-13 مقدمة

عندما ننظر الى الدراسات والبحوث القياسية التجريبية في مجال تحليل الظواهر الإقتصادية نجد أن هناك عدداً كبيراً من العلاقات الإقتصادية هي العلاقات المعبر عنها بمعادلة واحدة (The Single-Equation Type) ، لقد كان هذا هو السبب في تركيزنا على هذا النوع من العلاقات الإقتصادية في الفصول السابقة ، في تلك النماذج ذات المعادلة الواحدة هناك متغير واحد معتمد (Y) مثلاً . ويعرض هذا المتغير المعتمد في دالة خطية تحتوي على متغير توضيحي واحد أو أكثر مثل (X_1, X_2) (Explanatory Variables) وفي مثل هذه النماذج إفتراضاً ضمناً إن علاقة السبب بالتأثير (Cause-effect relationship) بين المتغير المعتمد (Y) والمتغيرات التوضيحية $(X_1, X_2, X_3, \dots, X_n)$ هي علاقة باتجاه واحد : إذ إن المتغيرات التوضيحية تمثل السبب (Cause) والمتغير المعتمد هو التأثير (effect) .

ولكن هناك حالات أو مواقف تكون فيها العلاقة بين المتغيرات الإقتصادية ذات إتجاهين أو طريقتين ففي التأثير (Tow-way Flow of Influence) وهذا يعني إن متغيراً إقتصادياً واحداً يؤثر على متغير إقتصادي واحد أو أكثر وذلك المتغير بدوره يتأثر بالمتغيرات التي أثر عليها . وهكذا في تحليل الإنحدار للعلاقة بين النقود (M) وسعر الفائدة (R) ، فإن طريقة المعادلة الواحدة تفترض ضمناً ان سعر الفائدة ثابت وتحاول تجد درجة إستجابة النقود المطلوبة للتغيرات الحاصلة في مستويات سعر الفائدة ولكن ماذا يحدث اذا كان سعر الفائدة يعتمد على الطلب على النقود .

في هذه الحالة فإن التحليل الذي يعتمد على المعادلة أو الدالة الواحدة غير ملائم وذلك لأن (M) الآن يعتمد على (R) وكذلك (R) يعتمد على (M) ،

وهكذا نحن بحاجة الى الإعتماد على معادلتين (Tow-equations) واحدة تربط (M) الى (R) والأخرى تربط (R) الى (M) . وهذا يقودنا الى إستخدام نماذج المعادلات الآنية والتي تحتوي على أكثر من معادلة إنحدار واحدة ، بحيث يكون هناك معادلة واحدة لكل متغير معتمد يدخل في علاقة متبادلة (Interdependent) .

13-2 طبيعة نماذج المعادلات الآنية

في نماذج المعادلة الواحدة كان التركيز على تقدير المعلمات والتنبوء بمعدلات قيم المتغير المعتمد (Y) المعتمدة على القيم الثابتة للمتغيرات التوضيحية ($X_1, X_2, X_3, \dots, X_n$) ولكن هذا التحليل بالنسبة لبعض العلاقات الإقتصادية لايعني شيئاً ، وذلك لأن تلك العلاقات ربما يعبر عنها على نحو أفضل باتجاهين للسببية ، فالمتغير المعتمد (Y) يتأثر بالمتغيرات التوضيحية ($X_1, X_2, X_3, \dots, X_n$) وكذلك المتغيرات التوضيحية تتأثر بالمتغير المعتمد (Y) ، لذلك من الأفضل أن نجمع مجموعة متغيرات مع بعضها البعض والتي يمكن أن تحدد بشكل آني أي في الوقت نفسه أو آنياً مع المجموعة المتبقية من المتغيرات ، وهذا هو ما نقوم به في بناء نماذج المعادلات الآنية ، في مثل هذه النماذج يوجد أكثر من معادلة واحدة (معادلة واحدة لكل مجموعة من المتغيرات المعتمدة أو الداخلية المرتبطة مع بعضها) .

في نماذج المعادلات الآنية لا يمكن تقدير المعلمات (parameters) لمعادلة واحدة دون أن نأخذ في الحساب المعلومات التي تزودنا بها بقية المعادلات الأخرى في نظام المعادلات الآنية .

مالذي سيحصل اذا قدرنا المعلمات لكل معادلة بتطبيق طريقة المربعات الصغرى الإعتيادية (OLS) دون النظر الى بقية المعادلات في نظام نموذج المعادلات الآنية ؟

من الإفتراضات المهمة جداً في طريقة المربعات الصغرى الإعتيادية (OLS) هو إن المتغيرات التوضيحية أما أن تكون غير احتمالية (Nonstochastic) أو اذا كانت احتمالية (stochastic) فهي توزع بمعزل عن المتغير العشوائي أو الخطأ المعياري الإحتمالي .

فإذا لم يحصل أي من هذين الإفتراضين فإن هذا يعني إن تقديرات طريقة المربعات الصغرى (Least-squares estimates) هي ليست فقط متحيزة وإنما أيضاً غير متسقة أو غير مترابطة منطقياً أو أن تقديرات المربعات الصغرى تكون متنافرة وهذا يعني أنه كلما زاد حجم العينة الإحصائية الى ما لا نهاية (indefinitely) ، فإن تقديرات المعلامات لا تميل الى الإقتراب من قيم المجتمع الإحصائي ، وهكذا في النظام الخيالي للمعادلات الآنية الآتي :

$$\begin{aligned} Y_1 &= b_0 + b_1 Y_2 + b_2 X_1 + U_1 \\ Y_2 &= b_0 + b_1 Y_1 + b_2 X_1 + U_2 \end{aligned}$$

عندما يكون (Y_1, Y_2) يعتمدان على بعضهما البعض أو المتغيرات الداخلية و (X_1) عبارة عن متغير توضيحي أو متغير خارجي (exogenous Variable) و (U_1, U_2) المتغير العشوائي أو الإحتمالي ، المتغيران (Y_1, Y_2) كلاهما إحتماليان (Stochastic) .

لذلك ما لم نبين أن المتغير الإحتمالي التوضيحي (Y_2) يوزع بمعزل عن (U_1) وكذلك نبين أن المتغير الإحتمالي التوضيحي (Y_1) يوزع بمعزل عن (U_2) فإن تطبيق طريقة المربعات الصغرى الإعتيادية (OLS) لهذه المعادلات أعلاه على نحو منفرد ستقودنا الى تقديرات متنافرة وغير منسقة .

3-13 مثال على نماذج المعادلات الآنية

المثال الأول : نموذج العرض والطلب

كما نعرف جيداً أن السعر (P) للسلعة والكمية منها (Q) المباعية يتقرران بتقاطع منحنى الطلب مع منحنى العرض للسلعة ، ومن اجل التبسيط نفترض أن منحنى الطلب ومنحنى العرض هما خطيان (Linear) ونضيف الى معادلات الطلب والعرض المتغير العشوائي (U₁) والمتغير العشوائي (U₂) وهكذا يمكن كتابة دالة الطلب ودالة العرض للسلعة كما يأتي :

$$\begin{aligned} Q^d_t &= b_0 + b_1 P_t + U_{1t} & b_1 < 0 & \text{دالة الطلب} \\ Q^s_t &= \alpha_0 + \alpha_1 P_t + U_{2t} & \alpha_1 > 0 & \text{دالة العرض} \\ Q^d_t &= Q^s_t & & \text{حالة التوازن} \end{aligned}$$

عندما يكون :

$$Q^d = \text{الكمية المطلوبة}$$

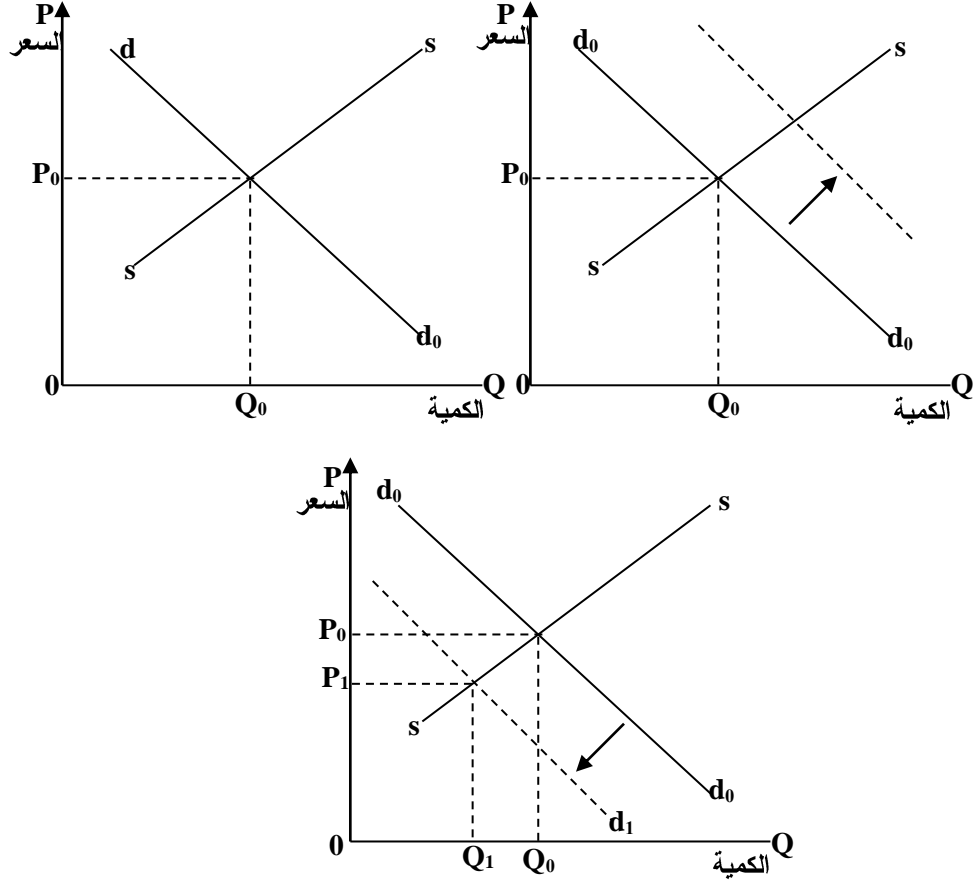
$$Q^s = \text{الكمية المعروضة}$$

$$t = \text{الزمن}$$

$$\alpha, \alpha_0, b_0, b_1 = \text{هي معلمات العلاقة}$$

على معلومات مسبقة فإن (b₁) من المتوقع ان تكون سالبة الإشارة (حيث منحنى الطلب يميل الى الإنحدار الى الأسفل) و α (1) من المتوقع أن تكون موجبة الإشارة (حيث منحنى العرض يميل الى الإنحدار الى الإرتفاع) .

في هذه الحالة ليس من الصعوبة في ان نرى أن السعر (P) والكمية (Q) يعتمدان على بعضهما البعض ، فإذا تغير (U_{1t}) مثلاً بسبب التغيرات في المتغيرات الأخرى المؤثرة في (Q_t^d) (مثلاً الدخل والثروة والذوق) فإن منحنى الطلب سيتحرك الى الأعلى اذا كان (U_{1t}) موجباً ويتحرك الى الأسفل اذا كان (U_{1t}) سالباً وهذه الحركة مبينة في الشكل (1-13) :



شكل (1-13) الإعتماضية بين السعر والكمية

وكما نرى من الشكل فإن التحرك في منحنى الطلب يغير السعر (P) وكذلك الكمية (Q) ، بالطريقة نفسها فإن التغيير في (U_{1t}) (بسبب الإضطرابات أو المناخ أو القيود على الإستيرادات والصادرات....الخ) سيحرك منحنى العرض ومرة أخرى هذا التحرك يؤثر في السعر (P) والكمية (Q) ، بسبب هذا الإعتماذ الآني (Simultaneous dependence) بين الكمية (Q) والسعر (P) وبين (U_{1t}) و (P_t) وبين (U_{2t}) والسعر (P_t) لا يمكن ان تكون علاقة مستقلة ، لذلك فإن دالة الإنحدار للعلاقة بين (Q) و (P) في معادلة الطلب سوف تخالف

فرضاً مهماً للنموذج الخطي التقليدي (الكلاسيكي) في عدم وجود ارتباط بين المتغيرات التوضيحية والمتغير العشوائي .

المثال الثاني : النموذج الكينزي في تقدير الدخل

لنأخذ نموذجاً كينزياً بسيطاً في تقرير الدخل :

$$C_t = b_0 + b_1 Y_t + U_t \quad 0 < b_1 < 1 \quad \text{دالة الإستهلاك}$$

$$Y_t = C_t + I_t (= S_t) \quad \text{متطابقة الدخل}$$

عندما يكون :

$$C = \text{الإنفاق على الإستهلاك}$$

$$Y = \text{الدخل}$$

$$I = \text{الإستثمار (متغير خارجي)}$$

$$S = \text{الإدخارات}$$

$$t = \text{الزمن}$$

$$U = \text{المتغير العشوائي}$$

$$b_1, b_0 = \text{معلمات دالة الإستهلاك}$$

المعلمة (b_1) تعبر عن الميل الحدي للإستهلاك (MPC)

(Marginal Propensity to Consume) وهو الكمية الإضافية من

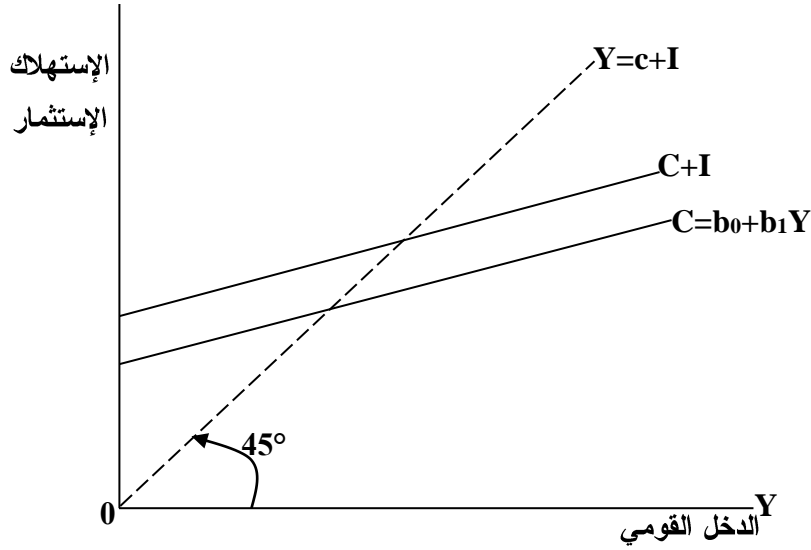
المصروفات الإستهلاكية الناتجة من إضافة دينار واحد الى الدخل . من النظرية

الإقتصادية نجد أن (b_1) تقع بين (0) و (1) ، إن دالة الإستهلاك أعلاه هي دالة

إحتمالية ومتطابقة الدخل تبين لنا أن الدخل الكلي يساوي المصروف الإستهلاكي

الكلي زائداً المصروف الإستثماري الكلي ومن المفهوم في النظرية الإقتصادية

أن الإستثمار الكلي يساوي الإدخار الكلي .



شكل (2-13) النموذج الكينزي في تقرير الدخل

من دالة الإستهلاك في الشكل (2-13) واضح ان (C) و (Y) هما متغيران معتمدان على بعض (أي أن هناك درجة من الإعتمادية بينهما) وأن المتغير (Y_t) في دالة الإستهلاك من المتوقع أن يكون غير مستقل عن المتغير العشوائي (U_t) وذلك عندما يتحرك (U_t) (بسبب عدد مختلف من العناصر) فإن دالة الإستهلاك أيضاً تتحرك وهذه بدورها تؤثر على (Y_t) .
ولذلك مرة أخرى نقول أن الطريقة التقليدية (الكلاسيكية) للمربعات الصغرى لا يمكن تطبيقها على هذه الدالة ، وإذا طبقت فإن التقديرات ستكون متنافرة وغير متطابقة مع المنطق .

13-4 حل تحيز المعادلات الآنية

طالما أن تطبيق طريقة المربعات الصغرى الإعتيادية (OLS) على معادلة تعود الى نظام من المعادلات الآنية تنتج تحيزاً وتقديرات للمعاملات غير متسقة فإننا يجب أن نطبق طرقاً أخرى لتقدير المعاملات في هذه الحالة تعطي تقديرات أفضل للمعاملات ، وهناك طرق عدة لهذا الغرض :

1- طريقة الشكل المختزل أو المصغر
(The Reduced Form)

أو طريقة المربعات الصغرى غير المباشر
2- طريقة المتغيرات الأدوات

(Instrumental Variables)

3- طريقة المربعات الصغرى بمرحلتين
(Two Stage Least Squares 2SLS)

4- طريقة الإحتمال الأعظم بمعلومات محدودة
(Limited Information Maximum Likelihood)

5- طريقة التقديرات المختلطة
(The Mixed Estimation Methods)

6- طريقة المربعات الصغرى بثلاثة مراحل
(Three-Stage LS)

7- الإحتمال الأعظم بمعلومات كاملة
إن الطرق الخمسة الأولى تدعى طرق المعادلة الواحدة
(Single-Equation Methods) وذلك لأنها تطبق على معادلة واحدة من
النظام في مرة ، أما طريقة المربعات الصغرى بثلاثة مراحل وطريقة الإحتمال
الأعظم بالمعلومات الكاملة تدعى طرق الأنظمة (Systems Methods) وذلك
لأنها تطبق على كل المعادلات المؤلفة للنظام على نحو آني .

13-4-1 بعض النماذج

1- النماذج التركيبية أو الهيكلية (Structural Models)

إن النموذج التركيبي أو الهيكل هو نظام كامل أو تام من المعادلات
التي تصف هيكل أو تركيب العلاقات بين المتغيرات الاقتصادية ، إن المعادلات

التركيبية أو الهيكلية (Structural Equations) تعبر أو تعرض المتغيرات الداخلية بوصفها دوال لمتغيرات داخلية أخرى ولمتغيرات مقررة مسبقاً ومتغيرات عشوائية ، وللتوضيح نستخدم النموذج البسيط لإقتصاد مغلق :

$$\begin{aligned} C_t &= a_0 + a_1 Y_t + U_1 \\ I_t &= b_0 + b_1 Y_t + b_2 Y_{t-1} + U_2 \\ Y_t &= C_t + I_t + G_t \end{aligned}$$

إن المعادلة الأولى هي دالة الإستهلاك والمعادلة الثانية هي دالة إستثمار والمعادلة الثالثة هي معادلة تعريفية .

ونظام هذه المعادلات تام وذلك لأنه يحتوي على ثلاثة معادلات مع ثلاثة متغيرات داخلية (C_t, I_t, Y_t) ، والنموذج يحتوي على متغيرين مقررين مسبقاً وهما المصروف الحكومي (G) والدخل المتخلف زمنياً (دخل السنة السابقة) (Y_{t-1}) ، ولغرض التبسيط سوف نتجاهل معاملات التقاطع (Intecepts) في المعادلات الهيكلية أو التركيبية .

إن المعلمات التركيبية بشكل عام هي إما ميول أو مروّنات أو أي معلمة في النظرية الإقتصادية ، والمعلمة الهيكلية تعرض أو تبين التأثير المباشر للمتغير التوضيحي على المتغير المعتمد . إن الآثار غير المباشرة يمكن أن تحسب بحل النظام الهيكلي فقط وليس من خلال المعلمات الهيكلية الفردية ، إن العناصر غير الظاهرة في أية دالة على نحو واضح ربما يكون لها أثر غير مباشرة على المتغير المعتمد لتلك الدالة ، مثلاً التغيير في الإستهلاك سوف يؤثر في الإستثمار على نحو مباشر من خلال تأثير الزيادة في الإستهلاك في الزيادة في الدخل (Y) الذي هو أحد المقررات المهمة للإستثمار .

إن تأثير (C) في (I) لا يمكن قياسه مباشرة في أي من المعلمات الهيكلية أو التركيبية ، ولكن يمكن أن نحسب هذا التأثير في الحل الآني للنظام . عادةً أو تقليدياً فإن المعلمات الهيكلية يعبر عنها بـ (b'_s) عندما تشير تلك المعلمات الى

متغيرات داخلية ، ويعبر عنها بـ (γ_s) عندما ترافق هذه المعلمات متغير مقرر مسبقاً ، إن المتغيرات التوضيحية يشار إليها بالحرف الصغير (y) ، بينما المتغيرات الخارجية يعبر عنها بالحرف الصغير (x_s) ، وباستخدام الإشارات التقليدية فإن النظام الهيكلي (Structural System) يصبح :

$$\begin{aligned} y_1 &= b_{13}y_3 + u_1 \\ y_2 &= b_{23}y_3 + \gamma_{21} + u_2 \\ y_3 &= y_1 + y_2 + x_2 \end{aligned}$$

عندما يكون :

$$\begin{aligned} y_3 &= Y \\ y_2 &= I \\ y_1 &= C \\ x_1 &= Y_{t-1} \\ x_2 &= G \end{aligned}$$

وعندما ننقل المتغيرات المشاهدة الى الجهة اليسرى نحصل على جدول

كامل للمعلمات الهيكلية أو التركيبية كما يأتي :

$$\begin{aligned} y_1 + 0y_2 + b_{13}y_3 + 0x_1 + 0x_2 &= u_1 \\ 0y_1 + y_2 - b_{23}y_3 - \gamma_{21}x_1 - 0x_2 &= u_2 \\ -y_1 - y_2 + y_3 + 0x_1 - x_2 &= 0 \end{aligned}$$

2- نماذج الشكل المختزل أو المصغر (Reduced Form Models)

إن هذه النماذج تدعى أيضاً طريقة المربعات الصغرى غير المباشرة (Indirect Least Squares) ، إن هذه النماذج هي إحدى طرق المعادلة الواحدة (Single-Equation) وفيها يتم استخدام معادلة واحدة للنظام في كل مرة ، إن هذه الطريقة ملائمة عندما تكون معادلات النظام الهيكلي أو التركيبي تحتوي على متغيرات مقرر مسبقاً ومتغيرات توضيحية بين مجموعة المتغيرات ويمكن توضيح طريقة الشكل المختزل بالخطوات الآتية :

الخطوة الأولى : نحصل على الشكل المصغر أو المختزل من النموذج

الهيكلية أو التركيبي عن طريق إعادة كتابة المعادلات بطريقة يعبر فيها عن

المتغيرات التوضيحية بوصفها دالة للمتغيرات المقرر مسبقاً ، وهكذا فإن المتغيرات التوضيحية في الشكل المصغر هي متغيرات خارجية على نحو حقيقي أو أنها قيم متخلّفة زمنياً (Lagged Values) للمتغيرات الداخلية ولذلك فإن موقفاً من التقرير المرتبط أو موقف السببية باتجاهين (Tow-Way Causation) للمتغيرات يبدو أنه تم تجنبه بإستخدام معادلة واحدة .

الخطوة الثانية : اذا حصلنا على الإفتراضات الإعتيادية حول الإضطراب (disturbance term) أو المتغير العشوائي لأية معادلة من معادلات الشكل المصغر ، عندئذ نطبق طريقة المربعات الصغرى لكل معادلة بصيغة الشكل المصغر ونحصل على تقديرات لمعادلات الشكل المصغر ، وهذه المعاملات يشار إليها تقليدياً بالحرف اليوناني (الإغريقي) (π) وهي خليط (a mixture) من معلمات النموذج الهيكلي أو التركيبي .

إن العلاقة بين معاملات الشكل المصغر (π) والمعاملات التركيبية أو الهيكلية $(b's)$ $(\gamma's)$ تشكل نظاماً من المعاملات تكون فيه معاملات الشكل المصغر معبر عنها بوصفها دوال للمعاملات الهيكلية أو التركيبية .
إن نظام العلاقات بين المعاملات التركيبية $(b's)$ $(\gamma's)$ ومعاملات الشكل المختزل $(\pi's)$ ربما تدعى نظام معاملات العلاقات .

الخطوة الثالثة : وهي الخطوة النهائية أو الأخيرة لطريقة المربعات الصغرى غير المباشرة تتألف من إستخدام تقديرات معاملات الشكل المصغر $(\pi's)$ التي يتم الحصول عليها من الخطوة الثانية أو السابقة وحل نظام معاملات العلاقات للحصول على معلمات تركيبية وإن هذه التقديرات ستكون وحيدة اذا كان النموذج مشخص تماماً ، ولتوضيح تطبيق طريقة المربعات الصغرى غير المباشرة سوف نقوم بأخذ مثال من نظرية تقرير أو تحديد السعر .

نفترض أن آلية السوق لسلعة معينة يمكن وصفها بالنظام الآتي من

المعادلات الآتية :

$$\begin{aligned} D &= a_0 + a_1P + a_2Y + U_1 \\ S &= b_0 + b_1P + b_2W + U_2 \\ D &= S \end{aligned}$$

عندما يكون :

$$D = \text{الكمية المطلوبة}$$

$$S = \text{الكمية المعروضة}$$

$$P = \text{السعر}$$

$$Y = \text{الدخل}$$

$$W = \text{حالة الجو أو المناخ}$$

إن هذا النموذج الهيكلي أو التركيبي وهو رياضياً نموذج كامل أو تام وذلك لأنه يحتوي ثلاثة معادلات بثلاث متغيرات داخلية (D,S,P) وهذا النظام يحتوي على متغيرين خارجيين هما الدخل (Y) وحالة الجو (W) . إن الشكل المصغر أو المختزل للنموذج الذي تعرض فيه المتغيرات الداخلية بوصفها دالة للمتغيرات الخارجية فقط يمكن أن نحصل عليه عن طريق التعويض المستمر .
أنها كما يأتي :

$$b_0 + b_1P + b_2W + U_2 = a_0 + a_1P + a_2Y + U_1$$

$$b_1P - a_1P = a_0 - a_2Y - b_0 - b_2W + U_1 - U_2$$

$$P(b_1 - a_1) = a_0 - b_0 + a_2Y - b_2W + U_1 - U_2$$

عندما يكون $v_2 = U_1 - U_2$ لدينا المعادلة الآتية :

$$P = \frac{a_0 - b_0}{b_1 - a_1} + \frac{a_2}{b_1 - a_1} Y + \frac{-b_2}{b_1 - a_1} W + v_2$$

$$D = a_0 + a_1P + a_2Y + U_1$$

$$D = a_0 + a_1 \left(\frac{a_0 - b_0}{b_1 - a_1} + \frac{a_2}{b_1 - a_1} Y + \frac{-b_2}{b_1 - a_1} W + \frac{U_1 - U_2}{b_1 - a_1} \right) + a_2 Y + U_1$$

$$D = a_0 + \frac{a_1(a_0 - b_0)}{b_1 - a_1} + \frac{a_1 a_2}{b_1 - a_1} Y + \frac{-a_1 b_2}{b_1 - a_1} W + \frac{a_1(U_1 - U_2)}{b_1 - a_1}$$

$$D = \frac{a_0(b_1 - a_1)}{b_1 - a_1} + \frac{a_1(a_0 - b_0)}{b_1 - a_1} + \frac{a_1 a_2}{b_1 - a_1} Y + \frac{-a_1 b_2}{b_1 - a_1} W + \frac{a_1(U_1 - U_2)}{b_1 - a_1}$$

$$D = \frac{a_0 b_1 - a_0 a_1}{b_1 - a_1} + \frac{a_1 a_0 - a_1 b_0}{b_1 - a_1} + \frac{a_1 a_2}{b_1 - a_1} Y + \frac{-a_1 b_2}{b_1 - a_1} W + \frac{a_1(U_1 - U_2)}{b_1 - a_1}$$

$$D = \frac{a_0 b_1 - \cancel{a_0 a_1} + \cancel{a_1 a_0} - a_1 b_0}{b_1 - a_1} + \frac{a_1 a_2}{b_1 - a_1} Y + \frac{-a_1 b_2}{b_1 - a_1} W + \frac{a_1(U_1 - U_2)}{b_1 - a_1}$$

$$D = \frac{a_0 b_1 - a_1 b_0}{b_1 - a_1} + \frac{a_1 a_2}{b_1 - a_1} Y + \frac{-a_1 b_2}{b_1 - a_1} W + \frac{a_1 U_1 - a_1 U_2}{b_1 - a_1} + a_2 Y + U_1$$

$$D = \frac{a_0 b_1 - a_1 b_0}{b_1 - a_1} + \frac{a_1 a_2}{b_1 - a_1} Y + a_2 Y + \frac{-a_1 b_2}{b_1 - a_1} W + \frac{a_1 U_1 - a_1 U_2}{b_1 - a_1} + U_1$$

$$\left\{ \begin{array}{l} \frac{a_1 a_2}{b_1 - a_1} Y + \frac{a_2 Y}{1} \\ \frac{a_1 a_2 Y + (b_1 - a_1) a_2 Y}{b_1 - a_1} \\ \frac{\cancel{a_1 a_2 Y} + a_2 b_1 Y - \cancel{a_1 a_2 Y}}{b_1 - a_1} \\ \frac{a_2 b_1}{b_1 - a_1} Y \end{array} \right\} = \frac{a_1 U_1 - a_1 U_2 + U_1(b_1 - a_1)}{b_1 - a_1}$$

$$= \frac{a_1 U_1 - a_1 U_2 + U_1 b_1 - a_1 U_1}{b_1 - a_1}$$

$$= \frac{U_1 b_1 - a_1 U_1}{b_1 - a_1}$$

$$D = \frac{a_0 b_1 - a_1 b_0}{b_1 - a_1} + \frac{a_2 b_1}{b_1 - a_1} Y + \frac{-a_1 b_2}{b_1 - a_1} W + \frac{U_1 b_1 - a_1 U_2}{b_1 - a_1}$$

وباستخدام الترميز التقليدي لمعاملات الشكل المختزل (π'_s) نحصل

على :

$$D = \pi_{10} + \pi_{11} Y + \pi_{12} W + v_1$$

$$P = \pi_{20} + \pi_{21} Y + \pi_{22} W + v_2$$

عندما يمكن أن نبين أن :

$$\begin{aligned}\pi_{10} &= \frac{a_0 b_1 - a_1 b_0}{b_1 - a_1} & \pi_{20} &= \frac{a_0 - b_0}{b_1 - a_1} \\ \pi_{11} &= \frac{a_2 b_1}{b_1 - a_1} & \pi_{21} &= \frac{a_2}{b_1 - a_1} \\ \pi_{12} &= \frac{-a_1 b_2}{b_1 - a_1} & \pi_{22} &= \frac{-b_2}{b_1 - a_1}\end{aligned}$$

بإستخدام بيانات عينة إحصائية للمتغيرات (W,Y,P,D) ربما نطبق طريقة المربعات الصغرى الإعتيادية (OLS) على معادلات الشكل المختزل (بأخذ معادلة واحدة كل مرة) للحصول على تقديرات لمعاملات الشكل المختزل (π'_s) .

ثم نقوم بإحلال القيم المقدرة لمعاملات الشكل المختزل (π'_s) في نظام علاقات المعاملات فنحصل على المعاملات الهيكلية الآتية :

$$\begin{aligned}a_0 &= \pi_{20} \left(\frac{\pi_{10}}{\pi_{20}} - \frac{\pi_{12}}{\pi_{22}} \right) & a_1 &= \frac{\pi_{12}}{\pi_{22}} \\ a_2 &= \pi_{21} \left(\frac{\pi_{11}}{\pi_{21}} - \frac{\pi_{12}}{\pi_{22}} \right) \\ b_0 &= \pi_{20} \left(\frac{\pi_{10}}{\pi_{20}} - \frac{\pi_{11}}{\pi_{21}} \right) & b_1 &= \frac{\pi_{11}}{\pi_{21}} \\ b_2 &= \pi_{22} \left(\frac{\pi_{12}}{\pi_{22}} - \frac{\pi_{11}}{\pi_{21}} \right)\end{aligned}$$

طالما أن المعادلات الهيكلية مشخصة تماماً ، فإن المعادلات تصف العلاقات بين المعاملات الهيكلية (b'_s) ومعاملات الشكل المختزل (π'_s) وهذه العلاقات تعطينا قيم وحيدة للمعاملات الهيكلية (b'_s) . وفي مثالنا فإن نظام علاقات المعاملات يحتوي على ستة معادلات في ستة مجاهيل (Unknowns) وهي المعاملات الهيكلية (a_2, a_1, a_0) (b_2, b_1, b_0) وبحل النظام يمكن الحصول على معاملات هيكلية مقدرة .

3- نماذج المربعات الصغرى بمرحلتين (2SLS) (Two-Stage Least Squares)

ثمة أسلوب عام ومباشر للحصول على تقديرات لمعاملات معادلة هيكلية مشخصة . وعلينا أن نستمر بالإفتراض أن لدينا عينة عشوائية من المشاهدات على كل من مشاهدات (Y) ومشاهدات (X) . وهذا الأسلوب هو أسلوب المربعات الصغرى بمرحلتين التي تعطي اسم (2SLS) ، في المرحلة الأولى نقدر كل معادلة شكل مختزل بطريقة المربعات الصغرى بالإنحدار الخطي ونحسب القيم الناتجة من هذا التقدير ، في المرحلة الثانية نأخذ كل معادلة هيكلية (Structural Equation) حسب دورها ونعوض عن كل متغير داخلي يقع في الجانب الأيمن من المعادلة بالقيمة المقدرة له في المرحلة الأولى وبعد ذلك نقوم بتقدير المربعات الصغرى بالإنحدار الخطي .

ولنكون أكثر تحديداً لنعمل عبر نموذج (A) الذي يتضمن الشكل الهيكلي

الآتي :

$$Y_1 = \alpha_1 Y_2 + \alpha_2 + \alpha_3 X_1 + U_1 \quad \text{الطلب}$$

$$Y_2 = \alpha_4 Y_1 + \alpha_5 + \alpha_6 X_2 + \alpha_7 X_3 + U_2 \quad \text{العرض}$$

والشكل المختزل لهذا النموذج هو :

$$Y_1 = \pi_1 + \pi_2 X_1 + \pi_3 X_2 + \pi_4 X_3 + V_1 \quad \text{الكمية}$$

$$Y_2 = \pi_5 + \pi_6 X_1 + \pi_7 X_2 + \pi_8 X_3 + V_2 \quad \text{السعر}$$

المرحلة الأولى : تقدير الشكل المختزل نحصل على :

$$\hat{Y}_1 = P_1 + P_2 X_1 + P_3 X_2 + P_4 X_3$$

$$\hat{Y}_2 = P_5 + P_6 X_1 + P_7 X_2 + P_8 X_3$$

ونخلق المتغيرات (\hat{Y}_1 و \hat{Y}_2) عند كل مشاهدة (\hat{Y}_1 و \hat{Y}_2)

المرحلة الثانية : بالنسبة لمعادلة الطلب نجري إنحدار (Y_1) على ثلاثة متغيرات (\hat{Y}_2) و (1) {وهو المتغير الذي يكون معاملته هو معلمة التقاطع} و (X_2) فنحصل على :

$$\tilde{Y}_1 = a_1^* Y_2 + a_2^* + a_3^* X_1$$

وبالنسبة لمعادلة العرض : نجري إنحدار (Y_2) على أربعة متغيرات هي :

(\hat{Y}_1) و (X_1) و (X_2) و (X_3) فنحصل على :

$$\tilde{Y}_2 = a_4^* Y_1 + a_5^* + a_6^* X_2 + a_7^* X_3$$

إن هذه المعلمات (a_s^*) هي تقديرات طريقة المربعات الصغرى بمرحلتين للمعلمات (α_s) .

فإذا كانت المعادلة الهيكلية (A Structural Equation) مشخصة تماماً فإن تقديرات طريقة المربعات الصغرى بمرحلتين تكون متطابقة أو متسقة مع تقديرات المربعات الصغرى غير المباشرة ، بينما إذا كانت المعادلة الهيكلية فوق التشخيص عندئذ فإن طريقة المربعات الصغرى بمرحلتين تربط بفعالية التقديرات البديلة لطريقة المربعات الصغرى غير المباشرة ، ولكن في كلا الحالتين فإن تقديرات طريقة المربعات الصغرى بمرحلتين (2SLS) تكون متسقة (Consistent) .

مثال : طريقة (2SLS)

لنأخذ نموذج إقتصادي جزئي وهو عن العرض والطلب على العمل :

$$\text{العرض : } Y_1 = \alpha_1 Y_2 + \alpha_2 + \alpha_3 X_1 + U_1$$

$$\text{الطلب : } Y_2 = \alpha_4 Y_1 + \alpha_5 + \alpha_6 X_2 + \alpha_7 X_3 + \alpha_8 X_4 + U_2$$

عندما يكون :

$$Y_1 = \text{الأشهر المشتغلة (الكمية)}$$

$$Y_2 = \text{معدل الأجور (السعر)}$$

وهذه هي متغيرات داخلية (Endogenous Variables) أما المتغيرات

الخارجية (Exogenous Variables) فضلاً عن متغيرات الواحد (1) فهي :

X1 حجم العائلة X2 التعليم X3 العمر X4 العنصر (الأصل)

وهي متغيرات غير مستقلة عن حدود الإضطراب الهيكلية (U₂, U₁) إن

حدود الإضطراب هذه لها قيم توقعات صفر وربما تكون مرتبطة ببعضها .

إن النظرية الإقتصادية للعرض والطلب تقول أن العمال يرغبون بالعمل

أكثر عند أجور أعلى ، بينما الشركات ترغب أن تدفع أجوراً أقل للعمل

الإضافي وهكذا فإن (α₁) موجبة (α₁ > 0) و (α₄) سالبة (α₄ < 0) ، إن

الشكل المختزل لهذا النموذج هو :

$$Y_1 = \pi_1 + \pi_2 X_1 + \pi_3 X_2 + \pi_4 X_3 + \pi_5 X_4 + V_1$$

$$Y_2 = \pi_6 + \pi_7 X_1 + \pi_8 X_2 + \pi_9 X_3 + \pi_{10} X_4 + V_2$$

عندما يكون :

$$\pi_1 - \alpha_1 \pi_6 = \alpha_2$$

$$\pi_2 - \alpha_1 \pi_7 = \alpha_3$$

$$\pi_3 - \alpha_1 \pi_8 = 0$$

$$\pi_4 - \alpha_1 \pi_9 = 0$$

$$\pi_5 - \alpha_1 \pi_{10} = 0$$

جانب الطلب

$$\pi_6 - \alpha_4 \pi_1 = \alpha_5$$

$$\pi_7 - \alpha_4 \pi_2 = 0$$

$$\pi_8 - \alpha_4 \pi_3 = \alpha_6$$

$$\pi_9 - \alpha_4 \pi_4 = \alpha_7$$

$$\pi_{10} - \alpha_4 \pi_5 = \alpha_8$$

عندما نقوم بتقدير النموذج بطريقة إنحدار المربعات الصغرى المباشرة على المعادلات الهيكلية نحصل على النتائج الآتية :

$$\tilde{Y}_1 = 0.271 Y_2 + 11.748 - 0.053 X_1$$

(0.260) (0.378) (0.073)

$$\tilde{Y}_2 = 0.003 Y_1 - 0.539 + 0.067 X_2 + 0.011 X_3 - 0.119 X_4$$

(0.034) (0.469) (0.011) (0.005) (0.146)

وطبعاً فإن هذه النتائج ينبغي عدم تفسيرها بوصفها تقديرات لمعادلات العرض والطلب الهيكلية .

ثم نستمر بالانتقال الى تقديرات طريقة المربعات الصغرى بمرحلتين ، ففي المرحلة الأولى تقدر معادلات الشكل المختزل السابقة بطريقة الإنحدار الخطي للمربعات الصغرى فنحصل على :

$$\hat{Y}_1 = 11.930 - 0.064 X_1 + 0.041 X_2 - 0.010 X_3 - 0.628 X_4$$

(0.912) (0.074) (0.033) (0.015) (0.436)

$$\hat{Y}_2 = 0.593 + 0.014 X_1 + 0.067 X_2 + 0.011 X_3 - 0.119 X_4$$

(0.302) (0.025) (0.011) (0.005) (0.144)

وبعد ذلك في المرحلة الثانية نضع هذه القيم المقدرة (\hat{Y}_2 \hat{Y}_1) على الجانب اليمين من معادلة العرض ومعادلة الطلب وكما يأتي :

$$\tilde{Y} = 0.767 \hat{Y}_2 + 11.420 - 0.054 X_1$$

العرض (0.472) (0.464) (0.075)

$$\begin{array}{ccccccc} \text{الطلب} & \tilde{Y} = & -0.218 & \hat{Y}_1 & + 2.013 & + 0.076 X_2 & + 0.009 X_3 - 0.259 X_4 \\ & & (0.462) & (5.330) & & (0.024) & (0.007) \quad (0.334) \end{array}$$

من وجهة النظر الإقتصادية فإن الصفة الأكثر أهمية لتقديرات (2SLS) بالمقارنة مع نتائج طريقة المربعات الصغرى المباشرة هي أن معامل الكمية في معادلة الطلب الآن أصبح لها الإشارة الصحيحة ومعامل السعر في معادلة العرض الآن أكبر .

الفصل الرابع عشر
التشخيص الإحصائي
Statistical Identification

التشخيص الإحصائي (The Identification)

1-14 مقدمة

من المعروف لدى المختصين بالإقتصاد القياسي أن معرفة الشكل المختزل لنظام من المعادلات ليس كافياً دائماً (ليس شرطاً كافياً) ليسمح لنا أن نتعرف على قيمة المعلمات في المنظومة أو المجموعة الأولى من المعادلات الهيكلية (Structural Equation). إن المشكلة المتعلقة في قدرتنا من عدمها على تقرير أو تحديد المعادلات الهيكلية عندما نعرف الشكل المختزل أو المختصر أو نحصل عليه تدعى مشكلة التشخيص (Identification Problem)، ولكن على كل حال يجب أن نلاحظ أن معرفة المعلمات الهيكلية (Parameters Structural)، ليس ضرورة مطلقة إذا كان التنبؤ هو غرضنا الأول، وذلك لأن التنبؤات يمكن أن نحصل عليها من خلال معادلات الشكل المختزل مباشرة.

إن أهمية مشكلة التشخيص تأتي قبل إعتبار مشكلة التقدير ففي اللحظة التي يحدد فيها النموذج الهيكلية، فإننا يجب أن ندقق فوراً أو حالاً من أجل معرفة في ما إذا كانت المعادلة أو المعادلات في النموذج مشخصة، بمعنى في ما إذا كان بإمكاننا أن نحصل على معرفة المعلمات في اللحظة التي يكون فيها الشكل المختزل قد تم تقديره، بعد التعامل مع مشكلة التشخيص والإنهاء منها نستطيع أن نتقدم للإختيار من بين أساليب التقدير.

إن الدالة دون أو أقل من التشخيص إذا لم يكن هناك طريقاً لتقدير جميع المعلمات الهيكلية من الشكل المختزل، والمعادلة تكون مشخصة إذا كان من الممكن الحصول على قيم المعلمات من معادلة الشكل المختزل، والمعادلة تكون مشخصة تماماً إذا كانت قيمة وحيدة (Unique Value) للمعلمة موجودة،

وتكون المعادلة فوق المشخصة (Overidentified) اذا كان بالإمكان الحصول على أكثر من قيمة واحدة لبعض المعلمات .

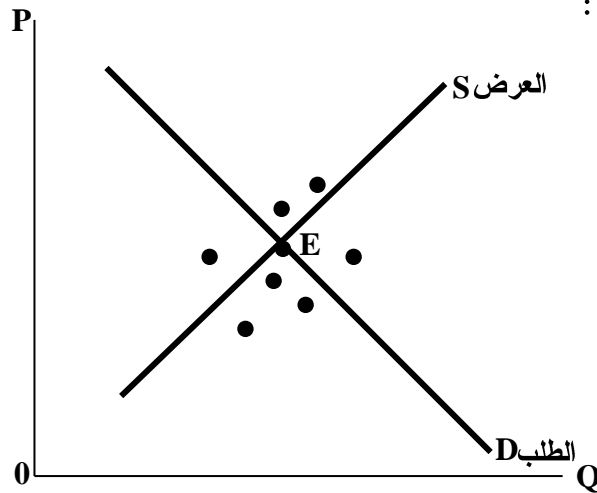
لننتقل الى المستوى العملي من خلال أخذ نماذج العرض والطلب ، فإذا أخذنا أولاً نموذج العرض والطلب لسلسلة زمنية ، والذي ليس فيه متغيرات مقررّة مسبقاً :

$$\text{العرض : } 2P_t \alpha_1 + \alpha Q_t = + \sum_t$$

$$\text{الطلب : } Q_t = B_1 + B_2 P_t + U_t$$

نفترض أن السوق في وضع توازني في كل فترة زمنية بحيث أن الكمية المطلوبة تساوي الكمية المعروضة ، إن العنصر الأساسي في فهم مشكلة التشخيص في سياق هذا النموذج هو ان يتم التركيز على حالة أو شرط التوازن. في كل فترة زمنية هناك فقط قيمة واحدة للسعر (P) ، وقيمة واحدة للكمية المباعة (Q) . بعبارة أخرى إن البيانات المتوافرة للمختص بالإقتصاد القياسي هي قيم السوق فقط (لكل فترة زمنية) للسعر (P) والكمية (Q) .

إن الأخطاء في المعادلات ستجعل من الممكن لقيم (P) و (Q) المتحصلة غير متشابهة ، ولكن من الممكن أن كل القيم سوف تقع بالقرب من القيم التوازنية لـ (P) و (Q) تقرر بالحل المباشر لمعادلات النموذج ، وهذا الموقف يبدو في الشكل الآتي :



فعندما نحاول أن نقدر معادلة العرض المنفصلة (Separate) ومعادلة الطلب المنفصلة باستخدام بيانات السوق نحصل على نتائج لا معنى لها ، ليس هناك إمكانية للتأكد من الميل الحقيقي للطلب والميل الحقيقي للعرض عندما تكون بيانات التوازن معروفة فقط . وفي الحقيقة فإن السبب الوحيد الذي يجعل التقدير ممكناً هو أن الأخطاء تظهر في كلا المعادلتين .

إن النموذج الذي نصفه هو نموذج يتضمن أن منحني العرض ومنحني الطلب غير مشخصين أو غير معرفين ، وإن كلا المعادلتين غير مشخصتين ، وذلك لأنه ليس هناك طريقاً للحصول على قيم للمعاملات الهيكلية (الميل ومعلمة التقاطع لمنحني الطلب الفردي ومنحني العرض الفردي) من معادلات الشكل المختزل أو المصغر ، إن معادلتني الشكل المختزل :

$$P_t = \frac{U_t - \varepsilon_t}{\alpha_2 - \beta_2} , \quad q_t = \frac{\alpha_2 U_t - \beta_2 \varepsilon_t}{\alpha_2 - \beta_2}$$

يجب أن يكون واضحاً من تفحص الشكل السابق أن أي زوج من منحنيي العرض والطلب يتقاطعان عند نقطة (E) ومن السهولة أن يبدو أنهما منحنيي العرض والطلب الحقيقي . بعبارة أخرى هناك عدد غير محدود من النماذج الهيكلية (منحني العرض والطلب) التي تتنسق مع الشكل المختزل نفسه (القيم التوازنية لـ (P) و (Q) .

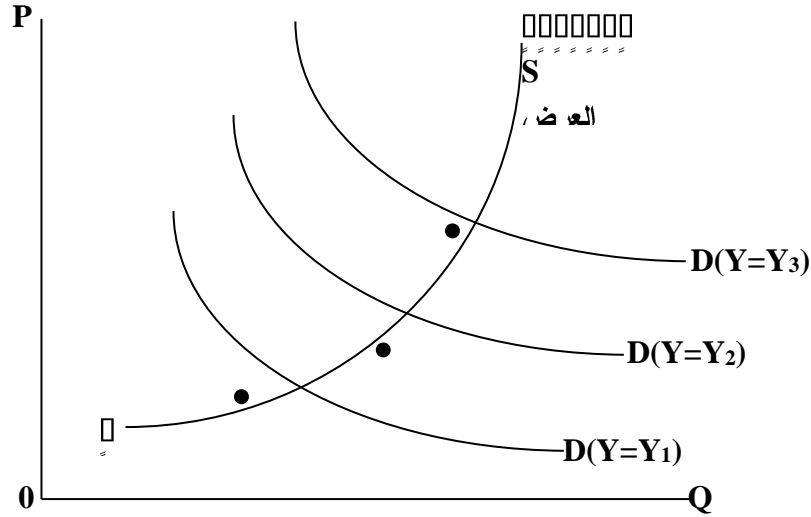
يجب أن يكون واضحاً إن تشخيص معادلات في نظام نموذج يتطلب بالضرورة معلومات أكثر من هذا النوع أو ذاك ، لنأخذ مثلاً نظام العرض والطلب السابق :

$$\text{العرض : } 2P_t \alpha_1 + \alpha Q_t = + \varepsilon_t$$

$$\text{الطلب : } Q_t = \beta_1 + \beta_2 P_t + \beta_3 Y_t + u_t$$

في ظل إفتراض أن $(0 \neq \beta_3)$ وأن (Y_t) تتغير عبر الزمن ، فإننا لا نستطيع أن نرسم منحني طلب واحد ومنحني عرض واحد لكل الفترات الزمنية.

ولأن الدخل يقرر الطلب والدخل يتغير عبر الزمن فإننا يجب أن نأخذ بنظر الاعتبار أو في الحساب الحقيقة التي تقول أن منحنى الطلب ينتقل عبر الزمن ، وهذا الوضع يوضحه الشكل الآتي :



شكل يوضح منحنى العرض المشخص

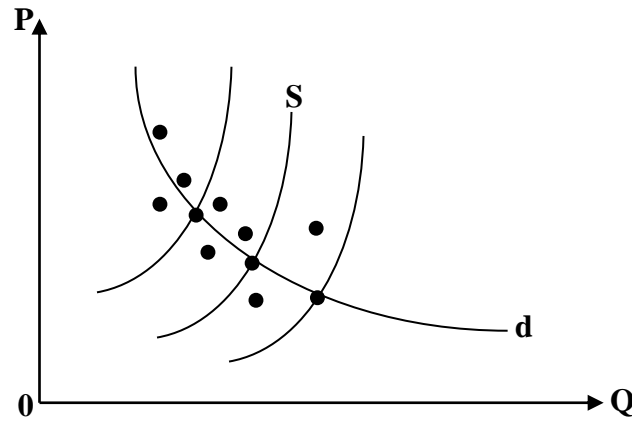
لأن منحنى الطلب ينتقل عبر الزمن فإن قيم التوازن لـ (P) و (Q) أيضاً تنتقل عبر الزمن . يجب أن يكون واضحاً من الشكل أن قيم التوازن تتبع مسار منحنى العرض ، وهكذا فإن منحنى العرض مشخصاً لأن معلمات العرض يمكن أن تستنتج من الشكل المختزل (الحركة في القيم التوازنية (P) و (Q) ، لاحظ ان الحركة التي يقوم بها (Y) عبر الزمن (أو عبر المشاهدات في تحليل المقطع العرضي) ضروري جداً لتشخيص معادلة العرض.

والان اذا أخذنا نموذج تكون فيه علاقة العرض مقررة بوساطة درجة الحرارة (T) في المنطقة ، و منحنى الطلب لا يتأثر بذلك ، عندئذ فإن معلومات مسبقة (a Priori information) حول متغير خارجي كان مستبعداً (درجة الحرارة) في معادلة العرض سوف يسمح لمنحنى الطلب أن يشخص ،

وطبعاً فإن منحنى الطلب ومنحنى العرض يمكن أن يشخصا ، والعلاقة الآتية للعرض والطلب تتضمن هذه الخاصية :

$$Q_t = \alpha_1 + \alpha_2 P_t + \alpha_3 T + \varepsilon_t \quad \text{: العرض}$$

$$Q_t = \beta_1 + \beta_2 P_t + \beta_3 Y_t + u_t \quad \text{: الطلب}$$



وكما ذكرنا سابقاً فإنه من المعادلات الهيكلية بإمكاننا أن نحل من أجل (M) من المتغيرات الداخلية ونشتق معادلات الشكل المختزل ومعلومات الشكل المختزل .

إن معادلة الشكل المختزل هي معادلة تعبر عن متغير داخلي على نحو وحيد بصيغ متغيرات مقررة مسبقاً ، وحد الإضطراب الإحصائي (Stochastic Disturbance) ، ولتوضيح هذا لنأخذ النموذج الكينزي في تقرير الدخل :

$$C_t = \beta_0 + \beta_1 Y_t + U_t \quad 0 < \beta_1 < 1 \quad \text{: دالة الإستهلاك}$$

$$Y_t = C_t + I_t \quad \text{: متطابقة الدخل}$$

في هذا النموذج فإن (C) الإستهلاك و (Y) الدخل هما المتغيران الداخليان وإن (I) الإستثمار (الإنفاق الإستثماري) يعامل هنا بوصفه متغيراً خارجياً . إن كلا المعادلتين هيكليتين ، ومعادلة الدخل هي متطابقة ، وكما هو معتاد فإن الميل الحدي للإستهلاك (MPC) أو (β_1) إفتترض أنها تقع بين الصفر والواحد فإذا عوضنا دالة الإستهلاك في دالة الدخل فإننا نحصل على الشكل المختزل :

$$\begin{aligned} Y_t &= \beta_0 + \beta_1 Y_t + U_t + I_t \\ Y_t - \beta_1 Y_t &= \beta_0 + U_t + I_t \\ Y_t(1 - \beta_1) &= \beta_0 + U_t + I_t \\ Y_t &= \frac{\beta_0}{1 - \beta_1} + \frac{1}{1 - \beta_1} I_t + \frac{U_t}{1 - \beta_1} \\ Y_t &= \underbrace{\frac{\beta_0}{1 - \beta_1}}_{\pi_0} + \underbrace{\frac{1}{1 - \beta_1}}_{\pi_1} I_t + W_t \end{aligned}$$

$$Y_t = \pi_0 + \pi_1 I_t + W_t \quad \text{معادلة الشكل المختزل (Y)}$$

ومعادلة الشكل المختزل هذه ل (Y) تعرض المتغير الداخلي (Y) وحيداً بوصفه دالة في المتغير الخارجي (I) وحد الإضطراب الإحتمالي (U) و (π_1, π_0) هي معاملات الشكل المختزل المرافقة . يجب أن نلاحظ أن هذه المعاملات للشكل المختزل توليفات غير خطية للمعاملات أو المعلمات الهيكلية ، نعوض عن قيمة (Y) الموجودة في الشكل المختزل في معادلة (C) الأولى في النموذج :

$$\begin{aligned}
 C_t &= \beta_0 + \beta_1(\pi_0 + \pi_1 I_t + W_t) + U_t \\
 C_t &= \beta_0 + \beta_1 \left(\frac{\beta_0}{1-\beta_1} + \frac{1}{1-\beta_1} I_t + \frac{U_t}{1-\beta_1} \right) + U_t \\
 C_t &= \beta_0 + \frac{\beta_1 \beta_0}{1-\beta_1} + \frac{\beta_1}{1-\beta_1} I_t + \frac{\beta_1 U_t}{1-\beta_1} + U_t \\
 C_t &= \frac{\beta_0(1-\beta_1) + \beta_1 \beta_0 + \beta_1 I_t + \beta_1 U_t + U_t(1-\beta_1)}{1-\beta_1} \\
 C_t &= \frac{\beta_0 - \beta_1 \beta_0 + \beta_1 \beta_0 + \beta_1 I_t + \beta_1 U_t + U_t - \beta_1 U_t}{1-\beta_1} \\
 C_t &= \frac{\beta_0}{1-\beta_1} + \frac{\beta_1}{1-\beta_1} I_t + \frac{U_t}{1-\beta_1} \\
 &\quad \uparrow \quad \quad \uparrow \quad \quad \uparrow \\
 &\quad \pi_2 \quad \quad \pi_3 \quad \quad W_t \\
 C_t &= \pi_2 + \pi_3 I_t + W_t
 \end{aligned}$$

إن معاملات الشكل المختزل (π_1, π_2) تعرف أيضاً بوصفها أثر المضاعفات (Multipliers) ، وذلك لأنها تقيس التأثير على المتغير الداخلي المتأثري من تغيير بوحدة واحدة في المتغير الخارجي .

ففي النموذج الكينزي السابق إذا ازداد الإنفاق الاستثماري (I) بمقدار دينار واحد ، وقد افترضت (MPC) (الميل الحدي للإستهلاك) لتكون (0.8) عندئذ فإن $(\pi_1 = 5)$ ، وهذا يعني زيادة الاستثمار بمقدار دينار واحد سيقود في النهاية الى زيادة في الدخل (5) خمسة دنانير ، وهذه زيادة خمسة مرات ، وبالطريقة نفسها فإن $(\pi_1 = 4)$ وهذا يعني زيادة دينار واحد في الاستثمار سوف تقود الى (4) دينار في الإنفاق الإستهلاكي .

14-2 مشكلة التشخيص الإحصائي

يتصف النموذج الإقتصادي القياسي بثلاثة خصائص :

- 1- المحتوى الإقتصادي (Economic Content) للنموذج
 - 2- الهيكل أو البناء الرياضي للنموذج (Mathematical Structure)
 - 3- الصفات الإحصائية للنموذج (Statistical Properties)
- إن الإتساق المنطقي (Logical Consistency) ، وكمال النموذج الإقتصادي القياسي تتقرر بالجانب الرياضي من النموذج ، أما الخصائص الإحصائية فهي تهتم بتقدير معلمات النموذج ، ومدى نجاح التقدير يعتمد على البيانات التجريبية وشكل النموذج ، فإذا لم يكن النموذج بالشكل الإحصائي الملائم ، فإن ذلك النموذج ينتج عنه معلمات ليس لها قيمة واحدة على الرغم من توفر البيانات الكافية ، وبلغة الإقتصاد القياسي فإن النموذج ربما لا يكون مشخصاً .

أ- مشكلة التشخيص (The Problem of Identification)

لنأخذ نموذج إقتصادي قياسي بسيط ساكن للسوق على سلعة واحدة (X) :

$$(1).....X_d = a_0 + b_0P + u$$

$$(2).....X_s = a_1 + b_1P + v$$

$$(3).....X_d = X_s$$

وفي هذا النموذج فإن :

$$X_d = \text{الكمية المطلوبة من السلعة } X$$

$$X_s = \text{الكمية المعروضة من السلعة } X$$

$$P = \text{سعر السلعة } X$$

$$u, v = \text{متغيرات عشوائية مختلفة}$$

$$a_1, b_1, a_0, b_0 = \text{معلمات المجتمع الإحصائي وهي ثوابت .}$$

فإذا كانت الثوابت (Constants) معروفة ، فإن المعادلات الهيكلية (Structural Equations) الثلاثة يمكن أن تحل للحصول الكمية المتبادلة وسعر التوازن إستناداً الى الأخطاء العشوائية (v,u) ، إن السعر الفعلي والكمية الفعلية المتبادلة هي نتيجة لتفاعل دوال العرض والطلب .

بالنسبة الى قيم معطاة للمعاملات هناك زوج وحيد للمتغيرين (P) و (X) يتقرر ، وهذا يمكن أن يعبر عنه هندسياً بوصفه تقاطع منحنى الطلب مع منحنى العرض . إفتراض إن بيانات عينة إحصائية تتألف من سلسلتين زمنيتين تبين سعر التوازن والكمية المتبادلة عبر كل فترة من الزمن والآن ينشأ السؤال التالي :

كيف نعرف أية معادلة يمكن أن تعبر عنها البيانات المشاهدة في السلسلة الزمنية ؟

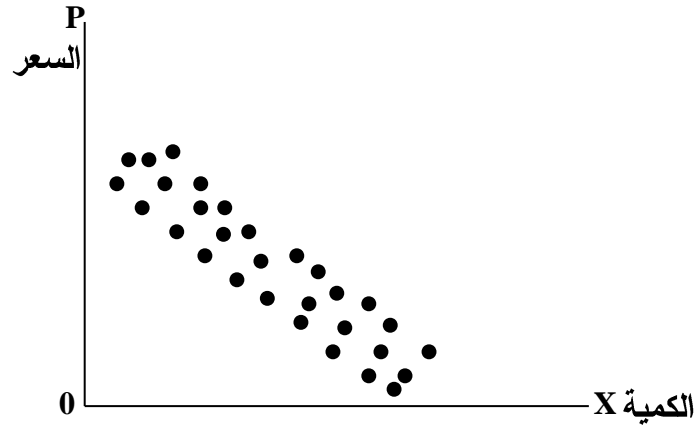
إن السلاسل الزمنية يمكن أن ترسم في شكل إنتشار ولكن كيف نستطيع أن نتأكد أن نقاط المشاهدة تقع على منحنى الطلب فقط أو على منحنى العرض فقط ؟ هذه الحالة هي مثال مشكلة التشخيص التي يجب أن نواجهها في نماذج الإقتصاد القياسي ، في هذه الحالة يجب أن نسأل في ما اذا كانت البيانات تشخص منحنى الطلب أو منحنى العرض أو خليط منهما ؟

في بعض الأمثلة من السهولة نسبياً أن نقرر ماذا تبين البيانات ، في ظل الظروف الآتية نستطيع أن نصل الى إستنتاجات معينة :

1- من المعروف أن منحنى الطلب لم يتغير عبر الزمن ، وإن منحنى العرض ينتقل كثيراً ، فإذا كانت هذه هي الحالة فإن معاملات معادلة الطلب في النموذج السابق هي في الحقيقة ثابتة ، ولكن معاملات معادلة العرض في الحقيقة قد تغيرت ، إن بيانات العينة الإحصائية سوف تبين نقاط منتشرة تقع فوق منحنى الطلب ، فإذا كان منحنى الطلب مستقراً نسبة الى منحنى العرض ،

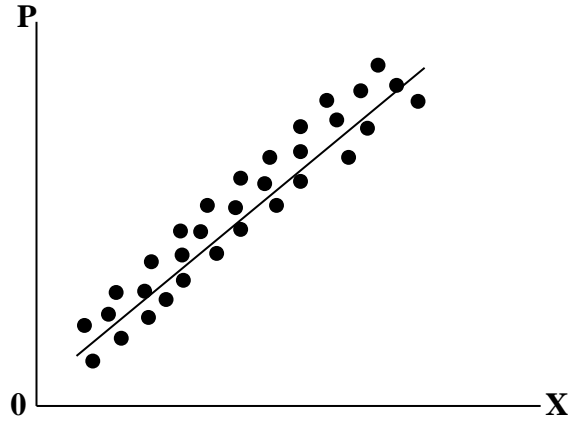
عندئذ فإن التغيرات في السعر والكمية المتاجر بها هي غالباً تعود الى إنتقال العرض .

إن شكل إنتشار العينة سوف يظهر مثل الشكل الآتي :



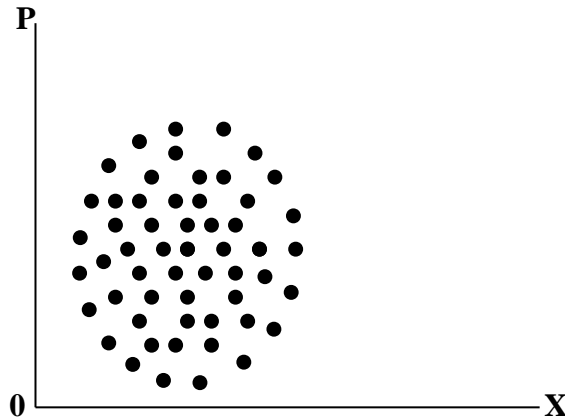
وبعد ذلك يمكن أن نقول أن منحنى الطلب شُخص من قبل البيانات ، إن هذا الوضع تتصف به السوق للسلع الزراعية المتعددة عندما تكون تأثيرات سقوط الأمطار أو فترة الحصاد أو الأنماط الموسمية لإنتاج الحليب تسبب إنتقالات عنيفة في منحنى العرض ، وعندما يكون هناك دليلاً جيداً أن معلمات منحنى الطلب (دخل المستهلك والأسعار الأخرى) قد تغيرت قليلاً جداً ، أو لم تتغير أبداً ، بينما معلمات منحنى الطلب قد تغيرت ، عندئذ فإن معادلة الطلب مثل المعادلة (1) السابقة يمكن أن تقدر بتحليل الإنحدار البسيط ، بمعادلة العرض مثل (2) لا يمكن أن تقدر .

2- من المعروف أن منحنى العرض لا يتغير بينما منحنى الطلب ينتقل على نحو كبير ، وهذه هي الحالة المعاكسة للحالة الأولى السابقة ، وهنا نقول أنه من المعروف أن معلمات دالة العرض (اسعار عناصر الإنتاج والحالات التكنولوجية) تتغير قليلاً أو لا تتغير بتاتاً ، ولكن معلمات الطلب تتغير ، فإن بيانات العينة الإحصائية سوف تبدو في الشكل الآتي :



والنقاط المشاهدة هنا تلحق (Trace Out) تقريباً منحنى العرض ، وهنا نقول أن منحنى العرض قد شخص أو أنه مشخصاً ، وفي هذا الموقف فإن الإنحدار البسيط يمكن أن يستخدم لتقدير معادلة العرض مثل المعادلة (2) السابقة ، ولكن دالة الطلب غير ممكن تقديرها .

3- من المعروف أن كلاً من منحنى الطلب ومنحنى العرض ينتقلان على نحو كبير ، وهذه الحالة هي المشتركة على الأغلب ، إن بيانات العينة الإحصائية تبين شكل الإنتشار الآتي :



عندئذ فإن الإنحدار البسيط للكمية المتاجر بها على سعر السوق لا تظهر معادلة الطلب أولاً أو معادلة العرض ، وإنما خليط من كليهما ، ونقول أن منحني الطلب غير مشخص ومنحني العرض أيضاً غير مشخص .

ب- معنى التشخيص الإحصائي

إن المناقشة السابقة يجب أن توفر لنا بعض التصورات في ما يتعلق بأهمية التشخيص ، ومع ذلك فإن التوضيح لا يعد كاملاً بأيّة طريقة وذلك بسبب وجود ثلاثة احتمالات مفتوحة :

الاحتمال الأول : هو ان النموذج ربما يكون تحت أو دون التشخيص (Underidentified) والذي فيه تكون مجموعة المعلمات الهيكلية غير ممكنة التقدير إحصائياً .

الاحتمال الممكن الثاني : إن النموذج ممكن أن يكون مشخصاً تماماً ، وعندئذ فإنه من الممكن عموماً أن نحصل على قيم وحيدة لكل المعلمات للمعادلات الهيكلية (Structural Equations) .

الاحتمال الممكن الثالث : إن النموذج يمكن أن يكون فوق المشخص (Overidentified) ، وإن تقدير قيم وحيدة (Unique) للمعلمات الهيكلية عملية ممكنة فقط في ظل شروط مقيدة .

إن الاحتمالات الثلاثة يمكن أن توضع بالصيغة الآتية :

(1) دون التشخيص

(2) مشخصاً :

- مشخص تماماً

- فوق التشخيص

فإذا كانت معادلة واحدة من النموذج دون التشخيص أي غير مشخصة (Not Identified) ، فإن النموذج يقال له أنه دون التشخيص أو غير مشخص ، وهكذا فإن النموذج المعروض في البحث السابق هو غير مشخص أو

دون التشخيص بغض النظر عن شكل الانتشار الممكن . وبالطريقة نفسها فإن النموذج يقال أنه فوق التشخيص (Overidentified) إذا كانت أية معادلة فيه فوق التشخيص ، وأن النموذج المشخص تماماً يتطلب أن كل معادلة تكون مشخصة .

إن صفة دون التشخيص أو صفة فوق التشخيص هي صفات نوعية مختلفة للنموذج ، فالأولى هي صفة غير احتمالية ونقصد بذلك أن المعلومات الهيكلية يمكن تقديرها إحصائياً بغض النظر عن حجم ودقة البيانات في العينة الإحصائية ، ولذلك نركز هنا على الفرق بين نماذج دون التشخيص والنماذج المشخصة تماماً .

جـ قواعد التشخيص

لإغراض التشخيص يجب أن نستخدم نموذج السوق لسلعة واحدة ، ولكن يجب أن نتذكر أن المبادئ التي يتم تطويرها هنا تطبق على نحو متساوي على بقية النماذج الإقتصادية القياسية :

بالنسبة للسلعة X لدينا :

$$X_d = a_0 + b_0P + u \quad (1) \text{ معادلة الطلب}$$

$$X_s = a_1 + b_1P + v \quad (2) \text{ معادلة العرض}$$

$$X_d = X_s \quad (3) \text{ معادلة التوازن}$$

وفي هذا النموذج فإن الرموز تعني المعاني نفسها في النموذج الأول الذي عرض في البداية ، يجب أن نسأل أنفسنا أولاً هل أن النموذج تام منطقياً ، وهذا يعني أو يماثل القول : إذا كانت قيم الثوابت (b_1, a_1, a_0, b_0) معروفة فهل يمكن للنموذج أن يحل للوصول الى القيم التوازنية للمتغيرات الداخلية (اعتماداً على (v, u) ؟ .

نلاحظ أن هناك ثلاثة متغيرات وثلاثة معادلات في هذا النموذج ، ولذلك فإن النموذج منطقياً تام .

فإذا أقنعنا أنفسنا بأن قيم المتغيرات يمكن أن تقرر إذا كانت قيمة الثوابت معروفة ، فإننا بعد ذلك نسأل في ما إذا كان ممكناً تقدير الثوابت أو معلمات المجتمع الإحصائي إحصائياً ، وهذه هي مشكلة التشخيص ، قبل وضع الشروط التي يجب توافرها حتى يكون النموذج مشخصاً يجب أن نعيد التعريفات ، فالمعادلات الهيكلية هي من نوعين : المعادلات السلوكية (Behavioral Equations) وهي تحتوي على متغيرات نظامية ومتغيرات عشوائية والتي تكون فيها المتغيرات النظامية أما متغيرات داخلية (Endogenous Variables) أو متغيرات خارجية (Exogenous Variables). وبقدر تعلق الأمر بالتشخيص ، فإننا يجب أن نهتم بالمعادلات السلوكية التي تحتوي على متغيرات داخلية ، وفي النموذج السابق فإن المعادلات (1) و (2) هي من هذا النوع ، وليس هناك متغيرات خارجية في النموذج ، المعادلة (3) هي النوع الثاني وهي معادلة تعريفية ، وبعبارة أكثر تحديداً هي معادلة تعريف التوازن .

ننتقل الآن الى قواعد التشخيص التي طورت من قبل أعضاء في لجنة كاول (Cowles Commission at The University of Chicago) من أجل أن يكون النموذج مشخصاً من الضروري أن كل معادلة سلوكية تحتوي واحداً أو أكثر من المتغيرات الداخلية مشخصة ، فإذا كانت أية واحدة من هذه المعادلات غير مشخصة فإننا نقول أن النموذج نفسه غير مشخص .

أولاً - شرط الدرجة للتشخيص (Order Condition For Identification)

إن هذا الشرط يعتمد على قاعدة حساب عدد المتغيرات الموجودة والمتغيرات المستبعدة (Excluded) من معادلة معينة ، إن هذا الشرط ضروري ولكنه غير كاف لتشخيص معادلة معينة ، إن شرط الدرجة يمكن أن ينص على ما يأتي :

من أجل أن تكون المعادلة مشخصة (أية معادلة) فإن العدد الكلي للمتغيرات (داخلية وخارجية) المستبعدة من المعادلة يجب أن يساوي أو أكبر من عدد المتغيرات الداخلية في النموذج ناقصاً واحد ، ومعلوم انه في النموذج التام فإن عدد المتغيرات الداخلية يساوي عدد المعادلات في النموذج ، بعبارة أخرى فإن شرط الدرجة في بعض الأحيان يكتب بصيغة مساوية أخرى :

من أجل أن تكون أية معادلة مشخصة فإن العدد الكلي للمتغيرات المستبعدة (Excluded) منها والمتضمنة أو الموجودة في بقية المعادلات يجب على الأقل أن يساوي عدد المعادلات في نظام المعادلات ناقصاً واحد .

لنجعل :

$$G = \text{العدد الكلي للمعادلات} = \text{العدد الكلي للمتغيرات الداخلي}$$

$$K = \text{العدد الكلي للمتغيرات في النموذج (الداخلية والمقررة مسبقاً)}$$

$$M = \text{عدد المتغيرات (الداخلية والخارجية) الموجودة في معادلة معينة}$$

عندئذ فإن شرط الدرجة للتشخيص يمكن أن يكتب بصيغة الرموز :

$$(K - M) \geq (G - 1)$$

المتغيرات المستبعدة	\geq	العدد الكلي للمعادلات ناقصاً واحد
---------------------	--------	-----------------------------------

مثال : اذا كان هناك نظام يحتوي على (10) معادلات مع متغيرات عددها (15) ، عشرة منها متغيرات داخلية وخمسة متغيرات خارجية ، فإن معادلة تحتوي على (11) متغيراً تكون غير مشخصة ، بينما معادلة أخرى تحتوي (5) متغيرات تكون مشخصة .

أ- بالنسبة للمعادلة الأولى لدينا :

$$K=15$$

$$G=10$$

$$M=11$$

فإن شرط الدرجة :

$$(K-m) \geq (G-1)$$

$$(15-11) < (10-1)$$

وهذا يعني أن شرط الدرجة غير متحقق ، وأن المعادلة دون التشخيص .

ب- بالنسبة للمعادلة الثانية لدينا :

$$K=15$$

$$G=10$$

$$M=5$$

شرط الدرجة :

$$(K-m) \geq (G-1)$$

$$(15-5) < (10-1)$$

وهذا يعني أن شرط الدرجة متحقق

ثانياً - شرط الرتبة (The Rank condition For Identification)

ينص شرط الرتبة على أنه :

في أي نظام متكون من (G) من المعادلات فإن أية معادلة معينة تكون مشخصة إذا كان من الممكن بناء على الأقل محددة واحدة (One Determinant) لاتساوي صفر ومن رتبة (G-1) من معاملات المتغيرات المستبعدة من معادلة معينة ولكنها موجودة أو محتواة في بقية معادلات النموذج .

إن الخطوات المحددة لمتابعة تشخيص معادلة من معادلات نموذج

هيكلية (Structural Model) يمكن أن ندرجها كما يأتي :

أولاً : نكتب معاملات (Parameters) كل معادلات النموذج في جدول

منفصل ، آخذين بنظر الاعتبار أن معلمة المتغير المستبعد من معادلة معينة مساوية للصفر .

مثلاً : لنجعل النموذج الهيكلي هو :

$$y_1 = 3y_2 - 2X_1 + X_2 + U_1$$

$$y_2 = y_3 - X_3 + U_2$$

$$y_3 = y_1 - y_2 + 2X_3 + U_3$$

عندما يكون (y_1, y_2, y_3) هي المتغيرات الداخلية ، وإن (X_1, X_2, X_3) هي المتغيرات المقررة مسبقاً ، إن هذا النموذج يمكن إعادة كتابته بالصيغة الآتية :

$$-y_1 + 3y_2 + 0y_3 - 2X_1 + X_2 + 0X_3 + U_1 = 0$$

$$0y_1 - y_2 + y_3 + 0X_1 + 0X_2 + X_3 + U_2 = 0$$

$$y_1 - y_2 - y_3 + 0X_1 + 0X_2 - 2X_3 + U_3 = 0$$

فإذا تجاهلنا المتغيرات العشوائية (u_3, u_2, u_1) فإن جدول معلمات

النموذج هو كما يأتي :

المعادلات Equations	المتغيرات (Variables)					
	Y ₁	Y ₂	Y ₃	X ₁	X ₂	X ₃
المعادلة الأولى	-1	3	0	-2	1	0
المعادلة الثانية	0	-1	1	0	0	1
المعادلة الثالثة	1	-1	-1	0	0	-2

ثانياً : نشطب الصف من المعلمات للمعادلة التي يراد تشخيصها ، مثلاً إذا اردنا أن نختبر إمكانية تشخيص المعادلة الثانية من النموذج فإننا نشطب الصف الثاني من جدول المعلمات .

ثالثاً : نشطب الإعمدة التي فيها قيم معلمات لا تساوي صفراً في المعادلة التي نختبرها لأغراض التشخيص .
إن حذف الصف الملائم والأعمدة الملائمة يجعلنا نبقي مع معلمات لمتغيرات غير موجودة أو متضمنة في المعادلة المعنية (المعادلة قيد التشخيص) ولكنها موجودة في بقية معادلات النموذج .

مثلاً إذا كنا نختبر تشخيص المعادلة الثانية من النظام ، فإننا سوف نشطب العمود الثاني والعمود الثالث والعمود السادس من الجدول أعلاه وهكذا نحصل على الجدولين الآتيين :

Y ₁	Y ₂	Y ₃	X ₁	X ₂	X ₃		Y1	X1	X2
-1	3	0	-2	1	0	المعادلة الأولى	-1	-2	1
0	-1	1	0	0	1	المعادلة الثانية	1	0	0
1	-1	-1	0	0	-2	المعادلة الثالثة			

رابعاً : من المحددات من رتبة (G-1) وتفحص قيمها : فإذا كانت واحدة على الأقل من المحددات لا تساوي صفراً فإن المعادلة تكون مشخصة ، وإذا كانت كل المحددات من رتبة (G-1) تساوي صفراً فإن المعادلة تحت أو دون التشخيص .

في المثال السابق لإستكشاف تشخيص المعادلة الثانية من المعادلات الهيكلية فإننا نحصل على ثلاثة محدّدات من رتبة (G-1) = 3-1 = 2 وهي :

$$\Delta 1 = \begin{vmatrix} -1 & -2 \\ 1 & 0 \end{vmatrix} \neq 0 \quad \Delta 2 = \begin{vmatrix} -2 & 1 \\ 0 & 0 \end{vmatrix} = 0 \quad \Delta 3 = \begin{vmatrix} -1 & 1 \\ 1 & 0 \end{vmatrix} \neq 0$$

إن الرمز (Δ) يمثل المحددة (Determinant) نلاحظ أننا نستطيع أن

نشكل محددين من درجة $\begin{bmatrix} (G-1) \\ 3-1=2 \end{bmatrix}$ لا تساوي صفراً ، وهكذا فالمعادلة الثانية من النموذج مشخصة .

خامساً : ومن أجل أن نرى في ما اذا كانت المعادلة مشخصة تماماً (Exactly Identified) أو أنها فوق التشخيص (Overidentified) فإننا نستخدم شرط الدرجة $(G-1) \geq (K-m)$ مع المعيار (Criteria) الآتي :

إذا تحققت إشارة المساواة أي اذا كان :

$$(K-m) \geq (G-1)$$

فإن المعادلة مشخصة تماماً .

وإذا تحققت إشارة عدم المساواة (Inequality) أي اذا كان :

$$(K-m) > (G-1)$$

فإن المعادلة فوق التشخيص (Overidentified) .

في حالة المعادلة الثانية السابقة فإننا نجد أن :

$$K=6$$

$$G=3$$

$$M=3$$

$$(K-m) \geq (G-1)$$

$$(6-3) > (3-1)$$

ولذلك فإن المعادلة الثانية من النموذج هي فوق التشخيص ، إن تشخيص دالة معينة يتم أو ينجز من خلال إفتراض أن بعض المتغيرات في النموذج لها معلمة أو معامل يساوي صفر في هذه المعادلة ، بمعنى أننا نفترض أن بعض المتغيرات لا تؤثر مباشرة على المتغير المعتمد في هذه المعادلة . وهذا على كل حال إفتراض يمكن أن يختبر مع بيانات عينة إحصائية .

مثال : نموذج يصف سوق احد المنتوجات الزراعية :

$$D = a_0 + a_1P_1 + a_2P_2 + a_3Y + a_4t + u$$

$$S = \beta_0 + \beta_1P_1 + \beta_2P_2 + \beta_3C + \beta_4t + W$$

$$D = S$$

عندما يكون :

$$D = \text{الكمية المطلوبة}$$

$$S = \text{الكمية المعروضة}$$

$$P_1 = \text{سعر سلعة معطى}$$

$$P_2 = \text{أسعار بقية السلع}$$

$$Y = \text{الدخل}$$

$$C = \text{الكلفة (الرقم القياسي لأسعار عناصر الإنتاج)}$$

$$t = \text{الإتجاه الزمني}$$

في دالة الطلب يمثل الأذواق في دالة العرض يمثل التكنولوجيا .

شرط الدرجة (Order Condition)

$$(K-m) \geq (G-1)$$

وفي مثالنا نجد أن :

$$K=7$$

$$G=3$$

$$M=5$$

ولذلك فإن :

$$(K-m) = (G-1)$$

$$(7-5)=(3-1)$$

$$2=2$$

وهكذا فإن المعادلة الثانية تحقق الشرط الأول الضروري للتشخيص .

شرط الرتبة (Rank Condition)

إن جدول المعلمات الهيكلية للنموذج هو كما يأتي :

المعادلات Equations	المتغيرات (Variables)						
	D	P ₁	P ₂	Y	t	S	C
المعادلة الأولى	-1	a ₁	a ₂	a ₃	a ₄	0	0
المعادلة الثانية	0	β ₁	β ₂	0	β ₄	-1	β ₃
المعادلة الثالثة	-1	0	0	0	0	1	0

1-	a3
-1	0

	-1	d3	
$\Delta =$			$= (0)(-1) - (-1)(a3) = a3$
	-1	0	

إن قيمة المحددة لا تساوي صفر بمعنى أن $(a_3 \neq 0)$ وهكذا نرى أن شرط الدرجة وشرط الرتبة قد تحققا ولذلك فإن المعادلة الثانية من النموذج مشخصة ، وإلا بعد من هذا فإننا نرى أنه في شرط الدرجة فإن إشارة المساواة تحققت :

$$7 - 5 = 3 - 1 = 2$$

وبالنتيجة فإن المعادلة الهيكلية الثانية هي مشخصة تماماً
(Exactly Identified) .

الفصل الخامس عشر
تطبيقات وتمارين محلولة
*Applications and Solved
Exercises*

تطبيقات وتمارين محلولة

1-15 بعض التمارين المحلولة

1- إفتراض أنك أعطيت نموذج الإنحدار الآتي :

$$\hat{Y}_t = \beta_0 + \beta_1 X_t + U_t$$

عندما تكون المشاهدات حول (Y,X) هي

$$\begin{matrix} 4 & 7 & 5 & 6 & 8 \\ & & & & \end{matrix} = Y_t$$

$$\begin{matrix} 2 & 1 & 3 & 2 & 4 \\ & & & & \end{matrix} = X_t$$

المطلوب : قدر المعلمات (β_0 و β_1) وقدر الإنحراف المعياري للمتغير العشوائي .

الحل : المعادلات الطبيعية لهذا النموذج هي :

$$\sum Y_t = n\hat{\beta}_0 + \hat{\beta}_1 \sum X_t$$

$$\sum X_t Y_t = \hat{\beta}_0 \sum X_t + \hat{\beta}_1 \sum X_t^2$$

الحسابات التي يمكن أن نجريها هي :

$$\sum_{t=1}^5 X_t^2 = 34$$

$$\sum_{t=1}^5 X_t = 12$$

$$\sum_{t=1}^5 Y_t = 30$$

$$\sum_{t=1}^5 X_t Y_t = 74$$

$$N = 5$$

نطبق النتائج على المعادلتين الطبيعييتين :

$$30 = 5\hat{\beta}_0 + 12\hat{\beta}_1$$

$$74 = 12\hat{\beta}_0 + 34\hat{\beta}_1$$

وبحل هاتين المعادلتين نحصل على :

$$\hat{\beta}_0 = 5.075$$

$$\hat{\beta}_1 = 0.385$$

أما الإنحراف المعياري للمتغير العشوائي :

$$\hat{\sigma}_u^2 = \frac{\sum (Y_t - \bar{Y})^2}{n - 2} = 3.077$$

2- يوضح أحد محلي الإستهلاك إن دالة الإستهلاك :

$$C_t = \beta_0 + \beta_1 Y_t$$

غير مفيدة لأن النقاط (C_t, Y_t) في شكل الإنتشار لا تقع على خط مستقيم ، ويلاحظ ذلك المحلل أيضاً أنه في بعض الأحيان يرتفع (Y_t) ولكن (C_t) ينخفض ، ولذلك فهو يستنتج أن (C_t) هي ليست دالة في الدخل (Y_t) ، هل أن تحليله صحيحاً أم لا ؟ ولماذا ؟

الحل : إن تحليله غير صحيح لأنه أهمل صيغة الخطأ العشوائي (U_t) والتي تأخذ قيمة سالبة وقيمة موجبة ، ولكن قيمته المتوقعة $E(U_t)$ هي صفراً .
إن العلاقة $(C_t = \beta_0 + \beta_1 Y_t)$ هي ليست علاقة تامة ولكنها علاقة على مستوى الوسط الحسابي أو هي علاقة إحصائية .

3- اذا أعطيت المتغيرات (X_3, X_2, X_1) وكان تباین هذه التغيرات كما

يأتي :

$$\delta_3^2 = 5.0 \quad \delta_2^2 = 3.0 \quad \delta_1^2 = 1$$

فإذا علمت أن هذه المتغيرات تفسيرية أو توضيحية وإن (Y) هو المتغير المعتمد بحيث قدرت الدالة الآتية :

$$\hat{Y} = 13 - 2X_1 - 10X_3$$

المطلوب : أحسب تباین المتغير المعتمد (Y)

الحل : نستخدم علاقة أساسية للتباين لمجموع المتغيرات الإحصائية وهذه

العلاقة تنص على ما يأتي :

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n \quad \text{اذا كانت :}$$

والمتغيرات (X_n, \dots, X_1) هي متغيرات تفسيرية أو توضيحية عندئذ فإن :

$$Y \text{ تباين } = \beta_1^2 \delta_{x1}^2 + \beta_2^2 \delta_{x2}^2 + \dots + \beta_n^2 \delta_{xn}^2$$

فإذا طبقنا هذه الصيغة على السؤال الحالي نحصل على :

$$\begin{aligned} \text{Var}(Y) &= 4 + 27 + 500 \\ &= 531 \end{aligned}$$

4- يقال أن العوائل ذات الدخل المتوسط والعوائل ذات الدخل العالي في الدول المتقدمة تغادر مراكز المدن لأن الضرائب في المدن أعلى من الضرائب في مناطق الضواحي التابعة للمدن . إفتراض أن لدينا بيانات تتعلق بعدد من المدن في نقطة محددة من الزمن . ضع فرضية لهذه المشكلة أو الظاهرة بصيغة نموذج إنحدار .

أ- يمكن وضع نموذج إنحدار لتلك الفرضية كما يأتي :

$$Y_i = \beta_0 + \beta_1 (T_{ci} - T_{si}) + U_i$$

عندما يكون :

Y_i = معدل دخل العائلة في المدن

T_{ci} = معدل الضريبة في المدن

T_{si} = معدل الضريبة في ضواحي المدن

U_i = حد الإضطراب (المتغير العشوائي)

ب- يمكن وضع نموذج إنحدار آخر كما يأتي :

$$Y_i = \beta_0 + \beta_1 \frac{T_{ci}}{T_{si}} + U_i$$

وفي كلا الوضعين فإن قيمة (β_1) تكون أقل من الصفر (سالبة) فإذا

كان (T_c) أعلى نسبياً من (T_s) سوف نتوقع أن العوائل ذات الدخل المتوسط والدخل العالي تعيش في الضواحي .

5- لنأخذ النموذج الآتي :

$$Y_t = \beta_0 + \beta_1 X_t + U_t \dots \dots \dots (1)$$

وفي هذه المعادلة (1) نجد أن حد الإضطراب أو المتغير العشوائي

(U_t) يعتمد على المتغير المستقل (X) بالنمط الآتي :

$$U_t = \beta_2 + \beta_3 X_t + \varepsilon_t \dots \dots \dots (2)$$

عندما يكون (ε_t) هو المتغير العشوائي أو حد الإضطراب غير مستقل

عن (X_t) ، والذي تنطبق عليه كل الإفتراضات الموضوعية لتحليل الإنحدار .

إفترض أن (β_3) أكبر من الصفر ($\beta_3 > 0$) ، بين أو وضح إن (β_1)

في المعادلة (1) تقلل من تأثير (X_t) على (Y_t) .

الحل : نعوض المعادلة (2) في المعادلة (1) فنحصل على :

$$Y_t = (\beta_0 + \beta_2) + (\beta_1 + \beta_3)X_t + \varepsilon_t$$

6- لماذا يكون الوسط الحسابي المقدر من عينة إحصائية مكونة من

(30) مشاهدة أفضل من الوسط الحسابي المقدر من عينة إحصائية مكونة من

(20) مشاهدة ، وهل ان كلا الوسطين المقدرين غير متحيزين ؟

الحل : ليكون الوسط الحسابي لعينة الـ 20 مشاهدة (\bar{X}_{20})

ليكون الوسط الحسابي لعينة الـ 30 مشاهدة (\bar{X}_{30})

إعتماداً على حجم العينة الإحصائية ، وعندئذ اذا كانت كلا العينتين قد

سحبت من المجتمع الإحصائي نفسه فإن :

$$E(\bar{X}_{20}) = E(\bar{X}_{30}) = M$$

عندما يكون (M) هو الوسط الحسابي للمجتمع الإحصائي .

وهكذا فإن كلا الوسطين المقدرين غير متحيزين ولكن (\bar{X}_{30}) سوف

يكون مفضلاً على الآخر لأن تباين (\bar{X}_{30}) سيكون أصغر من تباين (\bar{X}_{20}) ،

ولذلك فإن إستخدام (\bar{X}_{30}) (العينة ذات 30 مشاهدة) سيقود الى حدود ثقة أضيق

وإختبارات للفرضيات يمكن الإعتماد عليها .

7- لنأخذ وضعاً يكون فيه عدد من الشركات موجوداً في مدينة معينة

يعتمد على معدل الضريبة النسبي ، إفترض أيضاً أنه على الرغم من أن فوائد

ضريبية ربما تحصل للمقيمين في المدينة كلما كان عدد المقيمين هناك أكثر ، ولكن معدل التلوث يكون أو سيكون أكبر . عن موقع الشركة وعلاقات التلوث بصيغ نماذج الانحدار .

الحل : لنجعل (N_t) = عدد الشركات المتواجدة في تلك المدينة

عندئذ فإن نموذج موقع الشركة ربما يعرض كما يأتي :

$$N_t = \beta_0 + \beta_1 \left(\frac{T_{1t}}{T_{2t}} \right) + U_{1t}$$

عندما يكون :

$$(T_{1t}) = \text{الضريبة في تلك المدينة}$$

$$(T_{2t}) = \text{متوسط معدل الضريبة في المدن المجاورة}$$

نحن نتوقع أن (β_1) أصغر من الصفر ، وبالطريقة نفسها لنجعل (P_t)

مقياساً للتلوث ، وعندئذ علاقة التلوث ربما تعرض كما يأتي :

$$P_t = \beta_2 + \beta_3 N_t + U_{2t}$$

وهنا نتوقع أن (β_3) أكبر من الصفر .

8- إذا أعطيت دالة الإنتاج الآتية :

$$Q_t = \left(\frac{1}{A} \right) L_t^{\beta_0} K_t^{\beta_1} e^{ut}$$

عندما يكون :

$$(Q) = \text{الإنتاج}$$

$$(t) = \text{الزمن}$$

$$(L_t) = \text{العمل}$$

$$(U_t) = \text{حد الإضطراب أو المتغير العشوائي}$$

$$(K_t) = \text{رأس المال}$$

إفترض أن القيمة المتوقعة للمتغير العشوائي $(E(U_t)=0)$ وأن $(E(U_t^2)=\delta^2)$ وأن (U_t) مستقل عن (K_t) (L_t) .
المطلوب : إقترح طريقة لتقدير المعلمات (β_1, β_0, A) .
الحل :

بإستخدام التحويل اللوغاريتمي نحصل على ما يأتي :

$$Q_t^1 = \beta + \beta_0 L_t^1 + \beta_1 K_t^1 + U_t$$

عندما يكون :

$$Q_t^1 = \text{Log}_e Q_t$$

$$B = \log_e \left(\frac{1}{A} \right)$$

$$L_t^1 = \text{Log}_e L_t$$

$$K_t^1 = \text{Log}_e K_t$$

ثم نقدر (β_1, β_0, B) ونأخذ $(\hat{A} = e^{-\hat{B}})$

9- إفترض إن المصروفات الإستثمارية لشركة معينة تعتمد على معدل سعر الفائدة ومعدل الأرباح والتغير في المبيعات بوصفها مؤشراً للتوقعات .
أ- أكتب نموذج لهذه العلاقة (نموذج إنحدار)
ب- إفترض إن الأرباح خلال فترة أو مدة العينة الإحصائية بالنسبة للشركة كانت في المدة 15% . ناقش أية مشكلات تنشأ في عملية تقدير النموذج .

الحل :

أ- يكون نموذج الإنحدار كما يأتي :

$$I_t = \beta_0 + \beta_1 r_t + \beta_2 \pi_t + \beta_3 \Delta S_t + U_t$$

عندما يكون :

$$(I_t) = \text{المصروفات الإستثمارية}$$

$$(\pi_t) = \text{معدل الربح}$$

$$(\Delta S_t) = \text{التغيير في المبيعات}$$

$$(r_t) = \text{معدل سعر الفائدة}$$

$$(U_t) = \text{حد الإضطراب أو المتغير العشوائي}$$

ب- إن المشكلة في تقدير هذا النموذج سببها التعدد الخطي التام ، وبصيغة أكثر تحديداً نقول اذا كان معدل الربح 15% لكل فترة زمنية فإننا لايمكن أن نقدر المعلمة (β_0) والمعلمة (β_1) .

10- اذا أعطيت النموذج الآتي :

$$C_t = \beta_0 + \beta_1 C_t + \beta_2 Y_t + \varepsilon_{1t} \dots\dots\dots(1)$$

$$Y_t = I_t + C_t \dots\dots\dots(2)$$

$$I_t = a_0 + a_1 Y_t + a_2 Y_{t-1} + a_3 r_t + \varepsilon_{2t} \dots\dots(3)$$

عندما تكون :

$$(C) = \text{المصروفات الإستهلاكية}$$

$$(I) = \text{الإستثمار}$$

$$(Y) = \text{الدخل}$$

$$(r) = \text{معدل سعر الفائدة}$$

إفترض أن (ε_1) (ε_2) غير مرتبطان ذاتياً ومستقلان عن (r_t) .

أ- حدد المتغيرات الداخلية والمتغيرات الخارجية في النموذج

ب- كيف ستقدر المعادلة (1) ؟

جـ كيف ستقدر المعادلة (2) ؟

الحل :

أ- المتغيرات الداخلية هي : $(I_t) (Y_t) (C_t)$

المتغيرات الخارجية هي : $(r_t) (Y_{t-1}) (C_{t-1})$

ب- إن المشكلة في المعادلة (1) هي أن (Y_t) مرتبطة بـ (ε_{1t}) ولذلك فإن الإجراء الصحيح هو أن تحل (\hat{Y}_t) محل (Y_t) ، نحصل على (\hat{Y}_t) من خلال إنحدار (Y_t) على كل المتغيرات الخارجية التي هي $(r_t) (Y_{t-1}) (C_{t-1})$ وهكذا نجد أن (\hat{Y}_t) ستكون :

$$\hat{Y}_t = \hat{\gamma}_0 + \hat{\gamma}_1 C_{t-1} + \hat{\gamma}_2 Y_{t-1} + \hat{\gamma}_3 r_t + U_t$$

تقدر المعادلة (1) في النموذج بالطريقة الإعتيادية بعد إحلال (\hat{Y}_t) محل (Y_t) أي أن المعادلات الطبيعية يمكن الحصول عليها من خلال المساواة للصفر القيم :

$$\sum \varepsilon_1^* = 0 \quad \sum (\varepsilon_1^*, C_{t-1}) = 0 \quad \sum (\varepsilon_1^*, \hat{Y}_t) = 0$$

15-2 بعض التطبيقات الإقتصادية القياسية

الحالة الأولى :

دراسة العلاقة بين الدخل الإجمالي والضرائب من خلال البيانات حول ولاية أمريكية ، إن كلاً من الدخل والضرائب تقاس بـ 100 مليون دولار ، وتم تقدير النموذج وإعطاء النتائج مع قيم إختبار (t) وضعت بين الأقواس كما يأتي :

$$\hat{Tax} = -0.305 + 0.14492$$

$$(-3.04) \quad (121.7)$$

$$R^2 = 0.997$$

$$d.f. = 49$$

$$F = 14.820$$

$$\hat{\delta} = 0.549$$

إن هذا النموذج يعطي توفيقاً جيداً جداً وذلك لأن 99.7 بالمائة من الإنحرافات في الضرائب موضح بواسطة الدخل . كما أن قيمة إختبار (F)

عالية جداً والتي تشير الى علاقة قريبة أو قوية ، إن قيمة إختبار (t) للمعلمتين ($\hat{\alpha}$ و $\hat{\beta}$) ذات قيمة معنوية عند مستوى معنوية 5% .

إن التأثير الحدي (Marginal Effect) للدخل على الضرائب هو (0.14492) ، وهذا يعني أن زيادة (100) دولار في الدخل من المتوقع أن تزيد الضرائب على مستوى المعدل بمقدار (14.49) دولار .
الحالة الثانية :

في هذه الحالة نعرض نموذج إنحدار خطي بسيط قد أخذ من البحوث المنشورة . ففي دراسة لكل من (Bell) ومورفي (Murphy) في (1969) ، تم تقدير هيكل الكلفة لشركات الصيرفة التجارية بإستعمال بيانات (SMSAs) (Standard Metropoliton Statistical Areas) في شمال غرب الولايات المتحدة الأمريكية ، وهنا نكتفي بجزء من تلك الدراسة .

إن البيانات هي من نوع بيانات المقطع العرضي لـ (41 SMSAs) لسنة (1965) ، في المرحلة الأولى من التحليل الذي عرضته هذه الدراسة تم تقدير العلاقة بين تكاليف العمليات المباشرة للمصارف وعدد من المتغيرات التوضيحية :

عدد الودائع تحت الطلب (demand deposit) ، سعر الفائدة على رأس المال ، الأجور ، أسعار المواد المستعملة في حسابات ودائع الطلب وغيرها من المتغيرات التوضيحية ، إن النموذج المستعمل هنا هو كما يأتي :

$$AC_t = AN_t^{\alpha} U_t$$

عندما يكون :

$$AC_t = \text{معدل الكلفة المقدر لـ } (t^{\text{th}}) \text{ مصرف}$$

$$N_t = \text{عدد حسابات ودائع الطلب}$$

$$U_t = \text{حد الإضطراب}$$

(A)(II) هي معلمات (Parameters) مجهولة مطلوب تقديرها ، وبأخذ لوغاريتم جانبي المعادلة السابقة فنحصل على :

$$\ln AC_t = \ln A + II \ln N_t + \ln U_t$$

$$= \alpha + \beta \ln N_t + U_t$$

وهذه سوف يوصفها نموذج لوغاريتمي مزدوج .

وفي الجدول الآتي نضع بعض النتائج التي حصلت من هذا النموذج

ولمدن مختارة في الولايات المتحدة الأمريكية :

قيمة t لمعلمة II					
المدينة أو المنطقة	Log A	II	t- Value for II	R ²	درجات الحرية
Rochester	3.3614	0.0044	0.6783	0.0280	16
Philadelphia	3.2861	0.0077	2.6291	0.0834	76
Syracuse	3.3177	0.0037	0.9602	0.1033	8
New Britain	3.7693	-0.0146	-4.3014	0.8605	3
New York	3.2795	0.0130	4.5137	0.2114	76
Buffalo	3.1543	0.0237	3.5389	0.6415	7

نلاحظ من الجدول أن عدداً قليلاً من (R²) ذات قيمة عالية ، إن نتائج الدراسة تشير الى أن وفورات الحجم (Economies of Scale) التي يمكن أن تتحقق من قبل المصارف الكبيرة يقابلها أو يعوض عنها (offset by) بإيجاد الفروع (branching) . وهكذا فإن المصارف الصغيرة يمكنها أن تعمل إقتصادياً (Economically) كما تعمل المصارف الكبيرة ذات الفروع الصغيرة العديدة أو الكثيرة .

الحالة الثالثة :

مثال حول مشكلة الارتباط الخطي المتعدد (Multicollinearity) ، في هذا المثال نربط بين الإنفاق المتراكم على إدامة السيارة وعمر السيارة وعدد الأميال المقطوعة ، لنجعل (E_t) الإنفاق المتراكم على إدامة السيارة في الزمن

(t) (باستثناء البنزين) لسيارة معينة (X_1) عدد الأميال المتراكمة بآلاف الأميال و(X_2) العمر (عمر السيارة) بالأسابيع منذ الشراء الأصلي ، وهنا يمكن ان يكون لدينا النماذج البديلة الآتية :

$$\text{النموذج الأول : } Et = \alpha_0 + \alpha_1 X_2 + U_1 t$$

$$\text{النموذج الثاني : } Et = \beta_0 + \beta_1 X_1 + U_2 t$$

$$\text{النموذج الثالث : } Et = \nu_0 + \nu_1 X_2 + \nu_2 X_1 + U_3 t$$

فالسيرة التي يتم سيارتها كثيراً سيكون لها مصاريف إدامه أكبر ، وبالطريقة نفسها فإن السيارة نفسها كلما كانت قديمة فإن تكاليف إدامتها تكون أكبر ، وأيضاً فإن السيارة التي لها عدد أميال مقطوعة أكبر من المحتمل جداً أن يكون لها إنفاق على الإدامة أكبر ، ولذلك نتوقع ان المعلمات (α_1 و β_1 و γ_1 و γ_2) أن تكون موجبة الإشارة وفي ما يأتي نتائج تقدير المعلمات وقيم إختبار (t) المرافقة لتلك النماذج الثلاثة :

النموذج الأول	$\hat{E}_t = -626.24 + 7.35 X_2$	$0.89 = \bar{R}^2$
	(-5.98) (22.16)	درجات الحرية = 55

النموذج الثاني	$\hat{E}_t = -796.07 + 53.45 X_1$	$0.85 = \bar{R}^2$
	(-5.91) (18.27)	درجات الحرية = 55

النموذج الثالث	$\hat{E}_t = 7.29 - 151.5 X_1 + 27.58 X_2$	$0.94 = \bar{R}^2$
	(0.06) (-7.06) (9.58)	درجات الحرية = 54

ثم تقدير هذه النماذج بإستعمال بيانات فعلية تخص سيارة تويوتا (1971) صالون وهي معروضة في الجدول الاتي :

جدول يبين بيانات عن كلفة إدامة سيارة تويوتا 1971 وعدد الأميال المقطوعة
(X_1) وعمر تلك السيارة بالأسابيع (X_2)

X_2	X_1	الكلفة	X_2	X_1	الكلفة
5	0.8	11	279	43.7	1182
12	3.0	16	281	44.3	1231
30	4.9	55	313	47.6	1244
40	7.1	66	326	48.9	1257
42	7.6	76	328	49.1	1260
53	10.1	83	329	49.2	1342
66	12.0	135	336.5	50.0	1356
73	12.8	160	338	50.1	1467
79	13.9	163	342.5	50.6	1518
101	18.6	211	344.5	50.8	1557
114	21.1	258	351	51.6	1565
129	23.2	322	366	53.2	1583
150	25.3	374	384	55.7	1609
180	28.7	408	388	56.0	2825
195	30.5	478	402	57.3	2893
196	30.6	489	432	60.2	2918
204	31.4	536	433	60.3	3011
212	32.9	590	436	60.6	3077
224	35.3	604	436	63.0	3095
227	35.3	704	456	63.7	3154
232	36.6	985	463.5	63.9	3162
235	37.0	1021	465	65.1	3217
239	38.1	1030	478	65.8	3274
249	39.5	1096	485	67.7	3320
260	40.7	1114	498.5	72.1	3329
271	43.0	1134	526	72.1	3401
272	43.1	1157	527	73.6	3412
275.5	43.2	1176	538	74.4	3425
276	43.4	1182			

من الملاحظ ان معلمة المتغير (X_1) موجبة الإشارة في النموذج الثاني فإنها سالبة الإشارة على نحو مهم إحصائياً في النموذج الثالث ، وهكذا فإن هناك تعاكس او تضارب في الإشارة ، أما معلمة المتغير (X_2) قد تغيرت على نحو كبير ومهم ، كما أن قيمة إحصاءة (t) للمتغير (X_2) والمتغير (X_1) هي أقل كثيراً في النموذج الثالث ، وهنا فإن السبب لوجود هذا التغيير المعنوي إحصائياً في النتائج هو الارتباط العالي (High Correlation) بين المتغيرين التوضيحيين (X_2, X_1) وفي هذه الحالة فإن الارتباط بينهما هو (0.996) ، وهنا نلاحظ من هذا المثال أن هذا الارتباط العالي بين المتغيرات التوضيحية يمكن ان يجعل معاملات الانحدار ليست ذات معنوية إحصائية عالية أو يعكس إشارات المعلومات على نحو مخالف لمنطق النظرية الإقتصادية ، إن مشكلة الارتباط الخطي المتعدد غير مقتصرة على متغيرين توضيحيين وإنما يمكن لهذه المشكلة أن تكون موجودة بين متغيرات توضيحية عدة .

وفي هذه الحالة اذا تم القيام بإنحدار (X_1) على المتغير (X_2) سوف نحصل على :

$$X_1 = 4.191 + 0.134 X_2$$

$$t \rightarrow (8.74) \quad (88.11)$$

إن قيمة إحصاءة (t) ذات معنوية إحصائية عالية جداً وإن قيمة معامل التحديد المعدل هي (0.993) كلها توشر علاقة قريبة من التامة بين المتغيرين ، فإذا عوضنا عن هذه العلاقة بين المتغير في معادلة النموذج الثالث فسوف نحصل على :

$$\hat{E} = 7.29 + 27.58 X_2 - 151.15(4.191 + 0.134 X_2)$$

$$= -626.18 + 7.33 X_2$$

وهذه النتيجة قريبة جداً من قيم النموذج الأول الذي تم تقديره .

مراجع الكتاب

مراجع الكتاب

- 1- Christ , C, Econometric Models and Methods , John Wiley and Sons , Inc , New York , 1966 .
- 2- Chow , C.C. , Econometrics , McGraw-Hill , New York , 1983 .
- 3- Draper , N.R and H.Smith , Applied Regression Analysis , John Wiley and Sons , Inc , New York , 1998 .
- 4- Epstein , R.J , A History of Econometrics , North-Holland , Amsterdam , 1987 .
- 5- Fisher , f , M , The Identification Problem , McGraw-Hill , 1966 .
- 6- Greene , W , Econometrics Analysis , Mcmillan , 3rd edition , New York , 1997 .
- 7- Goldberger , A.s , Econometric Theory , John Wiley and Sons , Inc , New York , 1964 .
- 8- Griliches , Z , and Intriligator , M.D (ed) Handbook of Econometrics , Vol III , Elsevier , Amsterdam , 1986 .
- 9- Goldberger , A.s , Introductory Econometrics , Harvard University Press , Cambridge , 1998 .
- 10- Gujarati , D.N , Basic Econometrics , McGraw-Hill , New York , 1995 .
- 11- Intriligator , M.D , Econometrics Models , Techniques and Applications , North Holland , Publishing Company , Amsterdam , 1978 .
- 12- Intriligator , M.D , Mathematical Optimization and Economic Theory , Englewood , cliffs , Prentice-Hall , Inc N.J. 1971 .
- 13- Kane , E.J. , Economic Statistics and Econometrics , Harper International , 1968 .
- 14- Kennedy , P. , A Guide To Econometrics , Cambridge , Mass : MIT Press , 1995 .
- 15- Klien , L. , R. , A Textbook of Econometrics , Row-Peterson , 1953 .

مراجع الكتاب

- 16- Kmenta,J., Elements of Econometrics, Macmillan, New York, 1971 .
- 17- Koutsoyiannis , A. , Theory of Econometrics , ELIBS with Macmillan , 1977 .
- 18- Leser , C. , Econometrics Techniques and Problems , Griffin , 1966 .
- 19- Maddala , G. , Introduction to Econometrics , Macmillan , New York , 1990 .
- 20- Mirer , T.W. , Economic Statistics and Econometrics , Englewood Cliffs , N.J. Prentice-Hall , 1995 .
- 21- Pindyck , R.S. , and Rubinfeld , D.L. , Econometric Models and Economic Forecasts , 1991 .
- 22- Plackett , R.L. , Regression Analysis , Clarendon Press , Oxford , UK , 1960 .
- 23- Rao , C. , R. , Linear Statistical Inference and its Application , 2nd ed , Wiley , New York , 1960 .
- 24- Rao P. , and Miller , R.L. , Applied Econometrics , Wadsworth Publishing Co , Inc. Belmont , Calif , 1971 .
- 25- Schmidt , P. , Econometrics , Mareel-Dekkar , New York , 1976 .
- 26- Schneider , H. , and Barker , G.P. , Matrices and Linear Algebra , 2nd ed , Reinhart and Winston .
- 27- Stewart , J. Understanding Econometrics , 2nd ed , Hutchinson , London , 1984 .
- 28- Stewart , J. Econometrics , Philip Allan , New York , 1991 .
- 29- Suits , D.B. , The Theory and Application of Econometric Models , Athens , 1963 .
- 30- Thiel , H. , Principles of Econometrics , North-Holland , 1972 .
- 31- Weisberg , S. , Applied Linear Regression , Wiley , New York , 1985 .

مراجع الكتاب

- 32- Wonnacott , R.J. , and Wonnacott , T.H. , Econometrics , Wiley , 1970 .
- 33- Wooldridge , J.M , Econometric Analysis of Cross Section and Panel Data , The MIT Press , Massachusetts , 2002 .
- 34- Wooldridge , J.M , Introductory Econometrics : A Modern Approach , Cincinnati , Ohio , South-Western , 2000 .